

Descritores Morfológicos para Identificação Automática de
Padrões Epileptiformes em Sinais de EEG

Mayara de Sousa

**UNIVERSIDADE FEDERAL DE SANTA CATARINA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA
ELÉTRICA**

Mayara de Sousa

**DESCRITORES MORFOLÓGICOS PARA IDENTIFICAÇÃO
AUTOMÁTICA DE PADRÕES EPILEPTIFORMES EM SINAIS
DE EEG**

Florianópolis

2016

Mayara de Sousa

**DESCRITORES MORFOLÓGICOS PARA IDENTIFICAÇÃO
AUTOMÁTICA DE PADRÕES EPILEPTIFORMES EM SINAIS
DE EEG**

Dissertação de Mestrado submetida
ao Programa de Pós-Graduação em
Engenharia Elétrica do Centro
Tecnológico da Universidade
Federal de Santa Catarina para a
obtenção do título de Mestre em
Engenharia Elétrica.

Orientador: Prof. Fernando Mendes
de Azevedo, Dr.Sc.

Florianópolis

2016

Ficha de identificação da obra elaborada pelo autor,
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Sousa, Mayara de Sousa
Descritores Morfológicos para Identificação Automática
de Padrões Epileptiformes em Sinais de EEG / Mayara de
Sousa Sousa ; orientador, Fernando Mendes de Azevedo
Azevedo - Florianópolis, SC, 2016.
118 p.

Dissertação (mestrado) - Universidade Federal de Santa
Catarina, Centro Tecnológico. Programa de Pós-Graduação em
Engenharia Elétrica.

Inclui referências

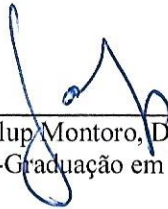
1. Engenharia Elétrica. 2. Engenharia elétrica. 3.
Eletroencefalografia. 4. Processamento de sinais. 5.
Descritores Morfológicos. I. Azevedo, Fernando Mendes de
Azevedo. II. Universidade Federal de Santa Catarina.
Programa de Pós-Graduação em Engenharia Elétrica. III. Título.

Mayara de Sousa

**DESCRITORES MORFOLÓGICOS PARA IDENTIFICAÇÃO
AUTOMÁTICA DE PADRÕES EPILEPTIFORMES EM SINAIS
DE EEG**

Esta Dissertação de Mestrado foi julgada adequada para obtenção do Título de Mestre em Engenharia Elétrica, área de concentração Processamento de Informação, subárea Engenharia Biomédica, e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Santa Catarina.

Florianópolis, 01 de abril de 2016.



Prof. Carlos Galup Montoro, Dr.
Coordenador do Programa de Pós-Graduação em Engenharia Elétrica

Banca Examinadora:

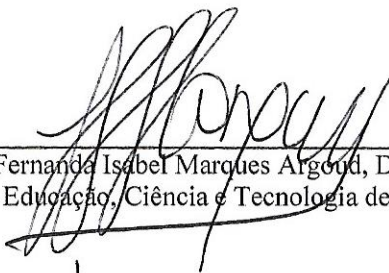


Prof. Fernando Mendes de Azevedo, Dr.Sc.
Universidade Federal de Santa Catarina
Presidente da banca e Orientador

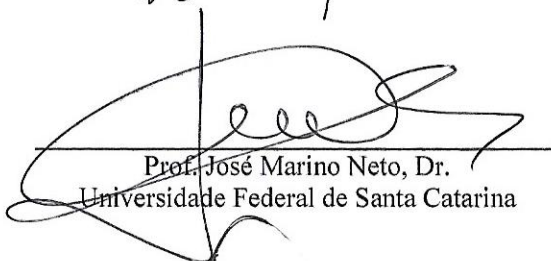
Banca Examinadora (continuação):



Prof^ª. Christine Fredel Boes, Dra.
Universidade Federal de Santa Catarina



Prof^ª. Fernanda Isabel Marques Argoud, Dra.
Instituto Federal de Educação, Ciência e Tecnologia de Santa Catarina.



Prof. José Marino Neto, Dr.
Universidade Federal de Santa Catarina



Prof. Renato Garcia Ojeda, Dr.
Universidade Federal de Santa Catarina

AGRADECIMENTOS

Agradeço a todos os meus familiares, mas em especial aos meus pais, Alcides João de Sousa e Celoni Florêncio de Sousa, pelo amor incondicional.

Ao meu esposo Peterson Fernando de Souza pelo amor incondicional, carinho, pelo apoio, incentivo, motivação, compreensão e muita paciência.

Ao professor Fernando Mendes de Azevedo e a Dr^a Christine Fredel Boos por todo o apoio, paciência e orientação que foram fundamentais na realização deste trabalho.

Aos professores do IEB-UFSC por todos os ensinamentos, oportunidades e trocas de ideias que foram muito importantes para o meu desenvolvimento acadêmico e pessoal.

Aos meus colegas no IEB-UFSC por suas palavras de apoio e incentivo, conversas e risadas. A amizade e a convivência com todos vocês foi muito importante para mim. Em especial Luciana Costa Ramos e Jorge Luiz da Costa Loureiro pelos laços de amizade desenvolvidos nesses anos.

Ao Programa de Pós-Graduação em Engenharia Elétrica da UFSC, IEB-UFSC e CAPES pela oportunidade e apoio financeiro para o desenvolvimento dos trabalhos realizados.

Ao meu amigo Leandro Schwarz (IFSC) que com sua ajuda, incentivo e puxões de orelha foram fundamentais para o término desta dissertação. Agradeço também a sua esposa Arline Cybelle Barcellos Faccin por toda paciência, amizade, carinho.

RESUMO

Na investigação da epilepsia, a análise de sinais de eletroencefalograma (EEG) é uma importante ferramenta para a confirmação clínica do diagnóstico, uma vez que a ocorrência de uma atividade eletrográfica específica neste sinal é um forte indicativo da presença da patologia. Estudos comparativos dos diversos métodos de detecção de padrões epileptiformes apontaram que os melhores resultados foram obtidos quando se utilizaram métodos que empregam alguma forma de parametrização dos sinais. Existem inúmeros estudos referentes à utilização de descritores morfológicos para a caracterização de sinais de EEG, entretanto, faz-se necessária uma análise detalhada quanto à contribuição de cada conjunto de descritores na detecção das descargas epileptiformes com uma mesma base de dados e metodologia. Dentro deste cenário o presente trabalho propõe-se a realizar uma revisão bibliográfica dos conjuntos de descritores morfológicos existentes na literatura e avaliar sua contribuição para a identificação automática de padrões epileptiformes. Para cada conjunto de descritores foi desenvolvido um algoritmo para calcular os descritores de forma automática, implementado uma rede neural para avaliar sua contribuição para a classificação dos padrões. E realizada a utilização de índices estatísticos sobre os conjuntos de descritores morfológicos. Com isso foi possível afirmar que quase todos os autores analisados apresentam resultados promissores, exceto um deles por não se tratar diretamente de descritores morfológicos no domínio do tempo e sim descritores morfológicos do padrão no domínio da frequência. Adicionalmente, os conjuntos que contém somente os descritores básicos mostram resultados equivalentes aos que resultaram de operação aritmética ou associação desses descritores básicos.

Palavras-chave: eletroencefalograma, padrões epileptiformes, descritores, processamento digital de sinais, inteligência artificial, reconhecimento de padrões.

ABSTRACT

In epilepsy research, analysis of electroencephalographic signals (EEG) is an important clinical tool for confirming the diagnosis, since the occurrence of a specific electrographic activity in this signal is a strong indication of its presence. Comparative studies of different detection methods of epileptiform patterns showed that the best results were obtained when the methods employ some form of signal parametrization. There are numerous studies on the use of morphological descriptors for characterizing EEG signals, however, it is necessary a detailed analysis on the contribution of each set of descriptors to the detection of epileptiform discharges using the same database and methodology. Within this scenario, the present work is proposed to conduct a literature review of existing sets of morphological descriptors in the literature and assess their contribution to the automatic identification of epileptiform patterns. For each set of descriptors it was developed an algorithm to automatically extract the descriptors and a neural network was implemented to assess their contribution to the classification of patterns. Some statistical indexes were used to quantify the classification performance. It was possible to notice that almost all authors analyzed showed promising results, except one of them, probably because its morphological descriptors are not directly extracted from the time domain. They are based on variables linked to the frequency domain. Also, the sets containing only the basic descriptors showed results equivalent to the ones that employ association or arithmetic operation of the basic descriptors.

Keywords: EEG, epileptiform patterns, descriptors, digital signal processing, artificial intelligence, pattern recognition.

LISTA DE FIGURAS

Figura 1 – Padrões eletrográficos do sinal de EEG	26
Figura 2 – Morfologia e respectiva denominação dos padrões epileptiformes mais encontrados em registros de EEG.....	27
Figura 3 – Diagrama ilustrativo da interconexão dos neurônios de uma rede neural artificial em arquitetura Perceptron Multicamadas.	34
Figura 4 – Modelo geral do neurônio artificial	35
Figura 5 – Comportamento da sensibilidade (linha sólida) e da especificidade (linha tracejada) em função do limiar de decisão (<i>threshold</i>).	49
Figura 6 – Ponto da taxa de erro igual (EER) obtida através do gráfico da sensibilidade e especificidade em função do limiar de decisão (<i>threshold</i>).	50
Figura 7 – Gráfico da Curva ROC.....	51
Figura 8 – Visão geral do presente trabalho.....	54
Figura 9 – Segmentos de sinal de EEG do banco utilizado contendo (a) espículas, (b) piscadas palpebrais, (c) atividade normal de fundo e (d) ruídos.	56
Figura 10 – Atividade, mobilidade e complexidade, e sua correlação com os domínios do tempo e da frequência.....	59
Figura 11 – Pontos e descritores utilizados por Frost (1979).	60
Figura 12 – Exemplo do método de segmentos e sequências.....	62
Figura 13 – Descritores definidos por Gotman (1980).....	64
Figura 14 – Pontos P_1 e P_2 apresentados por Ktonas e Smith (1974)....	66
Figura 15 – Descritores morfológicos apresentados por Ktonas <i>et al.</i> (1981).	68
Figura 16 – Pontos definidos por Lemieux e Blume (1983) e os parâmetros que serão utilizados para o cálculo dos descritores morfológicos.	69
Figura 17 – Janela de 100 amostras de sinal e representação gráfica dos descritores Amax, Bmin, DifAB e Tdif.....	71
Figura 18 – Janela de 100 amostras de sinal e representação gráfica dos descritores Amax_pts, Bmin_pts, DifAB_pts e Tdif_pts.	72
Figura 19 – Descritores de distância temporal, inclinação e amplitude descritos por Pereira (2003).	72

Figura 20 – Gráficos da (a) promediação de 500 espículas e (b) suas envoltórias superior e inferior, média e desvio padrão.....	76
Figura 21 – Distribuição da característica de amplitude de 1.000 espículas e o seu histograma correspondente.	76
Figura 22 – Interface gráfica para extração dos descritores morfológicos.	79
Figura 23 – Interface gráfica utilizada nas simulações e testes para implementação das redes neurais.	81

LISTA DE QUADROS

Quadro 1 – Tabela de contingência.....	39
Quadro 2 – Distribuição visual dos principais índices estatísticos.....	44
Quadro 3 – Principais momentos estatísticos associados à distribuição espectral e a correlação com as operações nas funções temporais.	58
Quadro 4 – Descritores utilizados por Ktonas e Smith (1974).	65
Quadro 5 – Descritores propostos por Ktonas <i>et al.</i> (1981).	67
Quadro 6 – Descritores morfológicos definidos por Lemieux e Blume (1983).	70
Quadro 7 – Descritores utilizados por Pereira (2003).	74
Quadro 8 – Descritores utilizados por Sovierzoski (2009).....	78

LISTA DE TABELAS

Tabela 1 – Relação dos autores e seus descritores morfológicos, separados pela similaridade do trabalho ou grupo de pesquisa.....	33
Tabela 2 – Composição dos conjuntos de padrões utilizados nas simulações.....	56
Tabela 3 – Relação dos autores e seus descritores morfológicos	57
Tabela 4 – Desempenho das RNAs utilizando o conjunto de Hjorth. ...	84
Tabela 5 – Desempenho das RNAs utilizando o conjunto de Frost.	87
Tabela 6 – Desempenho das RNAs utilizando o conjunto de Gotman.....	90
Tabela 7 – Desempenho das RNAs utilizando o conjunto de Ktonas <i>et al.</i>	93
Tabela 8 – Desempenho das RNAs utilizando o conjunto de Lemieux e Blume.	96
Tabela 9 – Desempenho das RNAs utilizando o conjunto de Pereira (2003).	99
Tabela 10 – Desempenho das RNAs utilizando o conjunto de Sovierzoski (2009).	102
Tabela 11 – Comparação entre os valores originais dos autores e os das simulações.....	104
Tabela 12 – Melhor desempenho de cada conjunto treinado e suas respectivas métricas de desempenho.....	106

SUMÁRIO

1 Introdução	21
1.1 Objetivos	22
1.1.1 Objetivo geral	22
1.1.2 Objetivos específicos.....	23
1.2 Organização do trabalho.....	23
2 Fundamentação Teórica	25
2.1 O Eletroencefalograma (EEG)	25
2.1.1 Automatização da Análise do EEG	28
2.2 Descritores Morfológicos	28
2.3 Redes Neurais Artificiais	34
2.4 Métricas de Análise de Desempenho	36
2.4.1 Prevalência	37
2.4.2 Tabela de Contingência.....	37
2.4.3 Inferir o resultado, conhecendo-se o padrão.....	39
2.4.3.1 Sensibilidade (<i>Sensitivity, Recall, True Positive Ratio</i> – TPR) .	40
2.4.3.2 Especificidade (<i>Specificity, True Negative Ratio</i> – TNR).....	40
2.4.3.3 Taxa de Erro (<i>False Positive Ratio</i> – FPR)	40
2.4.3.4 Taxa de Perdas (<i>False Negative Ratio</i> – FNR)	41
2.4.4 Inferir o Padrão, Conhecendo-se o Resultado	41
2.4.4.1 Valor Preditivo Positivo (<i>Positive Predictive Value</i> – PPV).....	41
2.4.4.2 Valor Preditivo Negativo (<i>Negative Predictive Value</i> – NPV) .	42
2.4.4.3 Taxa de Falsa Descoberta (<i>False Discovery Ratio</i> – FDR).....	42
2.4.4.4 Taxa de Falsa Omissão (<i>False Omission Ratio</i> – FOR).....	43
2.4.5 Índices de Desempenho Derivados dos Anteriores	43
2.4.5.1 Eficiência.....	44
2.4.5.2 Razão de Verossimilhança (<i>Likelihood Ratio</i> – LR)	45
2.4.5.3 <i>Diagnostics Odds Ratio</i> – DOR	46
2.4.5.4 Valor F (<i>F₁ score</i>)	46
2.4.5.5 Valor G (<i>G score</i>).....	47
2.4.5.6 Coeficiente de Correlação de Matthews.....	47
2.4.5.7 Correlação Aproximada	48
2.4.5.8 Índice de Youden (<i>Informedness</i>) e <i>Markedness</i>	48

2.4.6 Comportamento Sensibilidade vs. Especificidade.....	49
2.4.6.1 Taxa de Erro Igual (<i>Equal Error Ratio</i> – EER)	50
2.4.6.2 SnSpO e SpSnO	50
2.4.7 Análise ROC	51
3 Materiais e Métodos	53
3.1 Base de dados – Sinais de EEG.....	55
3.2 Conjunto de Descritores	56
3.2.1 Hjorth (1970).....	57
3.2.2 Frost (1979).....	59
3.2.3 Gotman (1980)	62
3.2.4 Ktonas <i>et al.</i> (1981).....	65
3.2.5 Lemieux e Blume (1983).....	68
3.2.6 Pereira (2003).....	70
3.2.7 Sovierzoski (2009)	75
3.3 Algoritmo para extração dos descritores	78
3.4 Rede neural artificial	80
3.5 Métricas de Análise do Desempenho	82
4 Resultados e Discussão	83
4.1 Conjunto de Hjorth (1970)	83
4.2 Conjunto de Frost (1979)	86
4.3 Conjunto de Gotman (1980).....	89
4.4 Conjunto de Ktonas <i>et al.</i> (1981).....	92
4.5 Conjunto de Lemieux e Blume (1983)	95
4.6 Conjunto de Pereira (2003)	98
4.7 Conjunto de Sovierzoski (2009).....	101
4.8 Análise Comparativa	104
5 Conclusão.....	107
6 Trabalhos Futuros.....	109
Referências	111

1 INTRODUÇÃO

A epilepsia é uma doença neurológica crônica, caracterizada por crises epiléticas recorrentes. Estas crises são breves episódios de movimentação involuntárias que podem envolver uma parte (crises parciais) ou todo o corpo (crises generalizadas), algumas vezes acompanhadas de perda de consciência e perda de controle intestinal e da bexiga. A estimativa mais recente da Organização Mundial de Saúde (WHO – *World Health Organization*) aponta que a epilepsia acomete cerca de 50 milhões de pessoas no mundo (WHO, 2015).

Uma das ferramentas utilizadas como auxílio no diagnóstico da epilepsia é a análise do eletroencefalograma (EEG) do paciente, buscando a ocorrência de padrões epileptiformes, principalmente espículas (PILLAI; SPERLING, 2006).

O processo de análise dos registros de EEG é uma tarefa lenta e cansativa, devido ao grande volume de sinais envolvidos. Um estudo comparativo realizado com 50 registros de EEG de curta duração apontou que os especialistas relataram ter gasto cerca de 60 horas para realizar a identificação dos primeiros 50 padrões epileptiformes de cada registro (WILSON *et al.*, 2003).

Ao longo de várias décadas, cientistas buscam criar metodologias e sistemas informatizados de identificação de padrões que possam reduzir o tempo necessário a revisão desses registros, além de aumentar a confiabilidade do processo, pois um especialista fadigado pode vir a cometer erros durante a análise do EEG (LUCCAS *et al.*, 1999).

Wilson e Emerson realizaram um estudo comparativo dos diversos métodos de detecção de padrões epileptiformes desenvolvidos entre 1976 e 2000. Neste estudo, os autores apontaram que os melhores resultados foram obtidos quando se utilizaram métodos que empregam alguma forma de parametrização dos sinais (WILSON; EMERSON, 2002).

Os primeiros estudos relacionados à parametrização dos sinais de EEG, com o objetivo de detectar padrões epileptiformes, foram publicados por Gotman e Gloor em 1976 e Gotman em 1982. Os estudos foram baseados na modelagem de espículas através de parâmetros que, neste trabalho, serão chamados de descritores morfológicos. Existem diversos estudos referentes à utilização de descritores morfológicos para a caracterização de sinais de EEG, entretanto, faz-se necessária uma análise comparativa detalhada quanto à contribuição de cada conjunto de descritores na detecção das descargas epileptiformes.

Apesar de existirem muitos estudos nesta área, a necessidade de automatização da análise dos sinais de EEG persiste, visto que ainda não se dispõe de um sistema com ampla utilização e desempenho ótimo. Uma dificuldade na comparação de trabalhos que utilizam descritores morfológicos é que as bases de dados e as métricas de avaliação são distintas.

Diante disto, este trabalho visa reproduzir os conjuntos de descritores morfológicos disponíveis na literatura, com uso de uma mesma base de registros de EEG de pacientes comprovadamente epiléticos.

Dado que diversos descritores morfológicos podem ser extraídos de um mesmo padrão, tais como amplitude e duração do sinal de EEG, de sua derivada primeira e de sua derivada segunda, é necessário se ponderar a contribuição de cada um destes descritores para a correta classificação do padrão em teste. A definição de regras de decisão específicas para cada um dos descritores apresenta uma complexidade elevada, que aumenta proporcionalmente à quantidade de descritores extraídos.

Diante deste cenário, o uso de redes neurais artificiais apresentam grande vantagem, permitindo que o treinamento da rede determine de forma iterativa quais descritores de um conjunto apresentam maior relação com a presença ou não de padrões epileptiformes.

1.1 OBJETIVOS

O presente trabalho norteia-se pelos seguintes objetivos.

1.1.1 Objetivo geral

Contribuir para o estudo e desenvolvimento do reconhecimento automático de padrões epileptiformes em sinais de EEG através da revisão dos conjuntos de descritores morfológicos presentes na literatura e avaliação da sua utilização na identificação automática de padrões epileptiformes com classificadores computacionais.

1.1.2 Objetivos específicos

- Revisão bibliográfica dos descritores morfológicos propostos na literatura;
- Desenvolvimento de algoritmos para o cálculo dos descritores morfológicos;
- Análise comparativa dos conjuntos de descritores morfológicos.

1.2 ORGANIZAÇÃO DO TRABALHO

O presente trabalho está organizado em cinco capítulos. Na introdução, é apresentado o problema a ser tratado, sua justificativa e os objetivos do trabalho.

O segundo capítulo apresenta a fundamentação teórica. O capítulo inicia com uma breve apresentação do sinal de eletroencefalografia, suas características de amplitude e frequência. Na sequência, é apresentada uma descrição das redes neurais artificiais (RNAs), sua definição e a topologia de RNAs Perceptron Multicamadas. O capítulo finaliza com a definição das principais métricas de desempenho de classificadores neurais binários apontadas na literatura.

O terceiro capítulo aborda a metodologia utilizada neste trabalho, descrevendo a base de dados utilizada, os conjuntos de descritores reproduzidos, o método de extração dos mesmos, as configurações das redes neurais utilizadas e as métricas de análise de desempenho.

O quarto capítulo apresenta os resultados obtidos com a implementação das redes neurais descritas no capítulo 3 e a análise comparativa entre os conjuntos de descritores.

Por último, as conclusões são apresentadas no quinto capítulo.

2 FUNDAMENTAÇÃO TEÓRICA

Os conceitos que servirão de aporte ao desenvolvimento da metodologia proposta neste trabalho são apresentados neste capítulo.

2.1 O ELETROENCEFALOGRAMA (EEG)

Epilepsia é uma síndrome caracterizada pela ocorrência de crises epiléticas. As crises epiléticas são ocorrências paroxísticas causadas por descargas anormais, excessivas e hipersincrônicas nos neurônios do sistema nervoso central (SNC).


Durantes as crises, diversas manifestações anormais no SNC podem ocorrer, incluindo atividade motora dramática e fenômenos sensoriais, dependendo da distribuição das descargas no SNC (LONGO *et al.*, 2012).

O eletroencefalograma é o registro da atividade encefálica obtido através de alguns métodos como de eletrodos posicionados na superfície do escalpo do paciente, eletrodos de profundidade, intra craneano, etc. Os sinais elétricos encefálicos (ou eletroencefalográficos) foram descobertos em 1875 pelo cientista inglês Richard Caton (1842-1926) que conectou um galvanômetro a dois eletrodos inseridos sob o escalpo de um voluntário. Desde então, os radicais eletro- (referente a sinais de origem elétrica), encefalo- (referente ao cérebro) e grama (ou grafia, referente ao registro) têm sido utilizados em conjunto para denotar o registro da atividade elétrica encefálica (SANEI; CHAMBERS, 2007b).

A análise de sinal de EEG é comumente utilizada para auxiliar no diagnóstico da epilepsia e na definição do tipo de síndrome epilética que ele pode vir a possuir, além disso, a análise deste exame serve como aporte ao planejamento da terapia e auxiliar na tomada de decisão sobre a viabilidade de intervenções cirúrgicas. O EEG apresenta características morfológicas que possibilitam a extração de sinais, tais como a banda de frequência de 0 a 100 Hz e faixa de amplitude de 2 a 200 μ V, o qual o sinal de interesse de padrões epileptiformes encontra-se entre 0,5 e 60 Hz, com amplitude média de 50 μ V. Estas características de amplitude e frequência do sinal podem ser influenciadas por vários fatores, tais como idade do indivíduo, estado

físico (sono, vigília, coma, dentre outros) e artefatos (ruídos) de várias fontes (SANEI; CHAMBERS, 2007b).

Conforme Sanei e Chambers (2007), o EEG é normalmente subdividido em faixas de frequências ilustradas na Figura 1



Fonte: modificado de Sanei e Chambers (2007)

De acordo com Sanei e Chambers (2007), as ondas de EEG apresentam característica específica de frequência e amplitude conforme listadas abaixo:

- Banda Alfa (α) – 8 a 13 Hz – Ritmo comum em pacientes normais e mais facilmente observável no indivíduo acordado, relaxado e com os olhos fechados;
- Banda Beta (β) – 13 a 22 Hz – Ritmo comum em pacientes adultos normais, durante o estado de vigília. Dominante na região pré-central do cérebro, mas aparecendo também em outras regiões cerebrais;
- Banda Teta (θ) – 4 a 8 Hz – Ritmo frequente em crianças, nas regiões central e temporal. Típico de estágios iniciais do sono. Alguns transientes de componentes deste ritmo têm sido encontrados em pacientes adultos normais;


- Banda Delta (δ) – 0,5 a 4 Hz – Ritmo comum em crianças, principalmente em recém-nascidos, em estado de sono profundo. Destaca-se que a presença desta onda em adultos sob estado de alerta pode indicar anormalidades.

A montagem dos eletrodos é outro aspecto a ser considerado na realização do exame de eletroencefalografia. Existem dois métodos utilizados normalmente na aquisição de sinais de EEG são o bipolar e o unipolar (ou referencial). No método bipolar, a diferença de potencial é medida entre um par de eletrodos e no método referencial em que, compara-se o potencial de cada eletrodo a um eletrodo de referência ou a média de todos os eletrodos. Sendo assim, a forma de onda do EEG depende do ponto onde será realizada a medição (MALMIVUO; PLONSEY, 1995).

A manifestação de tipos específicos de elementos eletrográficos no sinal de EEG são denominados padrões epileptiformes (EE), o qual são forte indicadores da presença de epilepsia (SANEI; CHAMBERS, 2007b).

Montenegro *et al.* (2012) apresentam a morfologia e denominações para os padrões epileptiformes mais encontrados em registros de eletroencefalogramas, como pode ser visualizado na Figura 2

Figura 2 – Morfologia e respectiva denominação dos padrões epileptiformes mais encontrados em registros de EEG



Fonte: Montenegro *et al.* (2012).

2.1.1 Automação da Análise do EEG

Sistemas automatizados de detecção de espículas podem utilizar como variável de entrada segmentos do próprio sinal de EEG ou características extraídas do sinal.

Nos métodos que utilizam segmentos do sinal de EEG, os segmentos, processados ou não, são utilizados como variáveis de entrada. Um dos processamentos mais utilizados é a Transformada *Wavelet* (TW). A TW isola as componentes de frequência no sinal com uma melhor resolução temporal (ARGOUD *et al.*, 2006).

Nos métodos que utilizam características dos sinais de EEG, informações são extraídas do sinal de EEG e são utilizadas como conjunto numérico de entrada para a classificação dos padrões presentes no sinal. Quando as informações são parâmetros relacionados à morfologia do sinal, tanto no domínio de tempo (amplitude, duração e inclinação) quanto no domínio da frequência (conteúdo espectral), as informações são chamadas de descritores morfológicos. Além dos descritores morfológicos, também é possível se referenciar as características referentes ao contexto do sinal (variância, entropia, localização no tempo, etc.) (HALFORD *et al.*, 2013; PEREIRA, 2003; SOVIERZOSKI, 2009; UBEYLI, 2009).

2.2 DESCRITORES MORFOLÓGICOS

Através da análise de registros de eletroencefalograma em papel, Weir (1965) demonstrou uma similaridade na amplitude e na duração de espículas. Kooi (1966) demonstrou que a atividade epileptiforme se caracterizava por segmentos com inclinações maiores que 2 $\mu\text{V/ms}$. A partir destes trabalhos, outros trabalhos utilizaram as inclinações do sinal de EEG no tempo para identificação de espículas, como por exemplo, o trabalho de Byford (1969), baseado no histograma da primeira derivada do sinal de EEG.

Hjorth (1970) se inspirou no trabalho de Byford (1969), e o expandiu para considerar também parâmetros estatísticos do histograma, gerando três descritores morfológicos para o intervalo analisado, a atividade, a mobilidade e a complexidade. Em seu trabalho posterior, Hjorth (1973) redefiniu o descritor complexidade, definindo-o como complexidade de primeira ordem.

Saltzberg, Heath e Edwards (1967) foram os pioneiros a utilizar a agudeza do sinal em métodos automatizados de detecção de atividade epileptiforme, através da correlação do sinal de EEG com a sua segunda derivada. Implementações deste método foram realizadas por Walter, Muller e Jell (1973), Hill e Townsend (1973) e Smith (1974).

A literatura apresenta diversas variações do método de Saltzberg, Heath e Edwards (1967), dentre elas, aquela apresentada por Carrie (1972). Nesta variação, após processar o sinal através de um filtro de média móvel, a medida da amplitude do sinal é utilizada como forma de complementação da informação dada pela segunda derivada, evitando assim, a necessidade de um ajuste do limiar de detecção para cada registro diferente. O método de Golberg, Samson-Dollfus e Gremy (1973) utilizou apenas a duração das ondas e sua amplitude em relação à atividade de fundo.

Outra variação do método de Saltzberg, Heath e Edwards (1967) foi apresentada por Gevins *et al.* (1975), que utilizaram a medida da curvatura no pico da onda em relação a um período de calibração fixo de quatro segundos. O método apresentado no estudo tornava o resultado da análise fortemente relacionado com as características da seção selecionada. Em contrapartida, o sistema também fazia uso de outras características, tais como duração da onda, presença de espículas em outros canais e rejeição de artefatos.

A maioria dos métodos citados é eficiente para a detecção de espículas, mas não detectam adequadamente as ondas agudas, além de apresentarem diminuição significativa da eficiência na presença de artefatos musculares. A partir desta análise de Gotman e Gloor (1976) concluíram que, embora a derivada segunda, analisada isoladamente, não seja uma medida suficiente para detectar a atividade epileptiforme, ela representa um dos seus aspectos morfológicos mais importantes. A maior contribuição do trabalho de Gotman e Gloor (1976) foi a descrição de um método de determinação dos pontos de início e final da espícula e a divisão do padrão em duas meias ondas, decomposição da onda. Métodos semelhantes de decomposição foram utilizados por muitos autores como Oliveira, Queiroz e Silva (1983), Faure (1985), Davey *et al.* (1989) e Webber *et al.* (1994).

Ktonas e Smith (1974) utilizaram um conjunto com seis descritores morfológicos baseados na duração, inclinação e agudeza do padrão. Em um trabalho posterior, Ktonas *et al.* (1981) incluíram descritores relacionados à amplitude do sinal, aumentando o conjunto para dez descritores.

Frost (1979) desenvolveu um sistemas de detecção de espícula que utilizava seis descritores morfológicos baseado em amplitude, duração e agudeza do sinal.

Ktonas *et al.* (1988) utilizaram descritores morfológicos para a identificação de espículas, aliados à informação contextual de outros canais de EEG e de outros sinais bioelétricos, como o ECG (Eletrocardiograma). Os autores citam que os descritores foram extraídos de características morfológicas do sinal, tais como duração e agudeza, porém, não especificam o número de descritores nem sua forma de extração.

Glover Jr. *et al.* (1989) e Glover Jr. *et al.* (1990) utilizaram um sistema baseado na informação contextual dos canais de EEG, ECG, EMG e EOG, além do posicionamento dos eletrodos, o estado de consciência do indivíduo e parâmetros referentes aos períodos antes e depois da ocorrência do padrão. A análise era realizada através da comparação dos valores de assimetria, amplitude e duração do padrão em teste com os valores médios de padrões reconhecidamente epileptiformes.

Davey *et al.* (1989), Jones e Dingle (1989), Dingle *et al.* (1993) e Jones e Dingle (1996) utilizaram o contexto espacial entre canais adjacentes e utilizam registro de EEG contínuo. Vera e Blume (1978) consideraram espículas como sendo ondas compostas por uma inclinação íngreme seguida por uma outra inclinação íngreme no sentido oposto dentro de 30 a 80ms, logo, o sistema interpretava o sinal como sendo uma espícula se a derivada do sinal excedesse um valor de comparação duas vezes, com reversão no sentido dentro de 30 a 80ms.

O método de decomposição de Gotman (1980) é utilizado em seu trabalho de 1980, no qual ele apresenta seis descritores morfológicos do sinal de EEG: utilizando a amplitude, a duração e a inclinação de cada meia onda do sinal. O método de Gotman (1980) é muito sensível à presença de transientes não-epileptiformes, tais como piscadas e artefatos de EMG. De modo a reduzir a incidências de falsos positivos, Gotman e Wang (1991) e Gotman e Wang (1992) incluíram a informação temporal e o contexto espacial (posicionamento dos eletrodos no escalpo), analisando 16 canais de EEG simultaneamente.

Lemieux e Blume (1983) utilizaram 16 descritores (oito para cada meia-onda), que são subdivididos em três categorias (inclinação, duração e amplitude), dos quais, seis descritores de inclinação, seis de duração e quatro descritores relacionados à amplitude. As máximas inclinações em cada meia onda, foram obtidas através do método de mínimos quadrados de cinco pontos de Vera e Blume (1978). Outros

pontos essenciais para o cálculo dos demais descritores foram obtidos através do método de decomposição de Gotman e Gloor (1976).

Oliveira, Queiroz e Silva (1983) utilizaram o desvio padrão da amplitude do sinal de EEG e de sua primeira e segunda derivadas para normalizar os valores correspondentes à amplitude, à inclinação e à curvatura do pico. Um método semelhante foi apresentado por Wilson *et al.* (1999), que utiliza características visuais (visualmente identificado por um especialista) ao invés de coordenadas físicas para a decomposição da forma de onda. Esta representação utiliza curvaturas e ângulos, ao invés de derivadas. Os autores defendem que o método pode representar de forma mais realista a análise visual realizada pelo especialista.

Eberhart, Dobbins e Webber (1989a), Eberhart, Dobbins e Webber (1989b) e Eberhart, Dobbins e Webber (1989c) utilizaram duas redes neurais artificiais para identificação de padrões epileptiformes. A primeira rede neural possuía como entrada uma janela do sinal de EEG em volta do padrão, enquanto que a segunda rede neural utilizava 25 descritores morfológicos extraídos do padrão, sendo nove deles relacionado à amplitude, à duração e à agudeza do padrão, e outros 16 relacionados à informação contextual presentes na janela em volta do padrão. Os três trabalhos apresentados não fornecem informação a respeito do nome ou da característica de formação destes descritores morfológicos.

Witte *et al.* (1991) não utilizam características visuais, mas sim, a potência e frequência momentânea calculada a cada amostra. Por avaliação visual, já com os picos marcados, os autores descobriram que a frequência momentânea apresentava baixa variação em comparação com o sinal de fundo e que a potência era alta. Limiares são aplicados para definir a aceitação de pico, e o uso primário para o presente método de detecção em registo automático (isto é, o posicionamento do cursor) do pico para a realização do mapeamento.

Wilson *et al.* (1999) usaram uma descrição de cinco meias-ondas. As duas meias-ondas habituais são as que descrevem, a forma triangular da onda. Também foi utilizada uma meia-onda antes e duas após o pico. Cada meia-onda é descrita pela sua duração, amplitude, inclinação e ângulo no início da meia onda. A classificação era realizada através de redes neurais artificiais. Hellmann (1999) desenvolveu um conjunto de 19 atributos para discriminar espículas de não-espículas. Ao invés de ser um detector autônomo, o sistema necessitava da interação com o usuário que inicialmente selecionava uma espícula como modelo (início e fim, duração e canal). O sistema, então, gerava uma lista de padrões que

apresentavam alta correlação com a espícula modelo. Alguns dos atributos considerados eram a inclinação, a altura, dentre outros, porém, muitos deles descreviam o quão bem o padrão em análise se correspondia com a espícula modelo. Uma rede neural simples era utilizada para selecionar os picos dos registros de ECoG (Eletrococleografia).

Pereira (2003) iniciou o trabalho estudando as características de segmentos de sinais com espículas, atividade de fundo normal, ondas alfa, ruídos e piscadas. Foram definidos 45 descritores, classificados em seis grupos de acordo com a grandeza envolvida: amplitude, duração, ângulo, distância, dados estatísticos e entropia.

Acir *et al.* (2005) apresentaram um trabalho baseado em duas redes neurais: uma rede de pré-classificação e uma rede de pós-classificação. A rede de pré-classificação utilizava os descritores de Gotman e Gloor (1976) como entrada para selecionar eventos supostamente epileptiformes em um registro corrido. Os eventos marcados por esta rede eram, então, avaliados pela rede de pós-classificação para determinar se o evento era epileptiforme ou não epileptiforme. A rede neural de pós-classificação não utilizava descritores morfológicos, analisando, apenas, o sinal de EEG janelado em torno do pico.

Kutlu, Kuntalp e Kuntalp (2009) utilizaram os mesmos descritores de Acir *et al.* (2005) processados através de quatro métodos de transformação: normalização, transformação não linear, análise de componentes principais e transformação *whitening*.

Halford *et al.* (2013) utilizaram os descritores apresentados por Acir *et al.* (2005) com intuito classificar padrões epileptiformes. Foram utilizados modelos de aprendizado de máquina para classificar a atividade EEG, entretanto, os autores concluíram que a base de dados que eles dispunham era muito pequena e precisava ser expandida para obtenção de resultados mais fidedignos.

Aarabi, Grebe e Wallois (2007) apresentaram um sistema de detecção composto por uma rede neural auxiliada por um sistema especialista baseado em regras. Os padrões de avaliação e treinamento utilizados eram provenientes de sinais de EEG de recém nascidos. O trabalho menciona a utilização de 50 descritores morfológicos, inclusive a utilização de informações contextuais provenientes da relação espacial e temporal entre canais de EEG. Observa-se, porém, que dos 50 descritores mencionados no trabalho, a informação de apenas 28 descritores é apresentada, de modo que os outros 22 descritores não são sequer citados.

Sovierzoski (2009) apresentava 30 descritores morfológicos, dos quais quatro são os mesmos apresentados por Gotman (1980). Estes quatro descritores foram combinados por operações matemáticas básicas para a obtenção de outros 18 descritores, sendo que, dois deles foram também apresentados por Lemieux e Blume (1983) e outros dois descritores foram obtidos pela inversão destes. Três outros descritores tratavam de valores absolutos de amplitude do sinal em momentos específicos do padrão e, por fim, foram utilizados mais quatro descritores obtidos através de tratamento estatístico para cálculo da média, desvio padrão (calculado através da variância), assimetria e curtose. O autor utilizava um classificador neural artificial para realizar a avaliação dos descritores morfológicos.

Uma pesquisa bibliográfica acerca dos conjuntos de descritores morfológicos descritos na literatura resultou na identificação de 28 estudos, apresentados na Tabela 1.

Tabela 1 – Relação dos autores e seus descritores morfológicos, separados pela similaridade do trabalho ou grupo de pesquisa.

Estudo	Número de Descritores
Hjorth (1970)	3
Hjorth (1973)	-
Ktonas e Smith (1974)	6
Frost (1979)	6
Ktonas <i>et al.</i> (1981)	10
Ktonas <i>et al.</i> (1988)	-
Glover Jr. <i>et al.</i> (1989)	-
Glover Jr. <i>et al.</i> (1990)	-
Gotman e Gloor (1976)	-
Gotman (1980)	6
Gotman e Wang (1991)	-
Gotman e Wang (1992)	-
Lemieux e Blume (1983)	16
Davey <i>et al.</i> (1989)	6
Jones e Dingle (1989)	-
Dingle <i>et al.</i> (1993)	7
Jones e Dingle (1996)	-
Eberhart, Dobbins e Webber (1989a)	3
Eberhart, Dobbins e Webber (1989b)	25
Eberhart, Dobbins e Webber (1989c)	-
Wilson <i>et al.</i> (1999)	-
Pereira (2003)	45
Sovierzoski (2009)	30
Acir <i>et al.</i> (2005)	6
Kutlu, Kuntalp e Kuntalp (2009)	6
Aarabi, Grebe e Wallois (2007)	50
Halford <i>et al.</i> (2013)	-


(-) não apresentam informações sobre a quantidade de descritores.

2.3 REDES NEURAIS ARTIFICIAIS

Dentre os métodos e ferramentas mais aplicados em sistemas de automatização de auxílio ao diagnóstico encontram-se as Redes Neurais Artificiais.

Redes Neurais Artificiais são modelos computacionais inspirados no sistema nervoso de seres vivos. Com capacidade de realizar a aquisição e manutenção do conhecimento baseado em informações. As redes possuem um conjunto de unidades de processamento, os neurônios artificiais, que são interligados através de inúmeras sinapses artificiais (número de interconexões), conforme pode ser visto na Figura 3.

Figura 3 – Diagrama ilustrativo da interconexão dos neurônios de uma rede neural artificial em arquitetura Perceptron Multicamadas.



Fonte: Adaptado de Boos (2015).


Partindo da inspiração do funcionamento do neurônio biológico o modelo geral do neurônio artificial foi desenvolvido. O neurônio artificial é composto por sete elementos básicos:

- Sinais de entrada $\{x_1, x_2, \dots, x_n\}$: São sinais provenientes do meio externo e que são usualmente normalizados visando incrementar a eficiência computacional dos algoritmos de aprendizagem;
- Pesos sinápticos $\{w_1, w_2, \dots, w_n\}$: São valores que servirão para ponderar cada uma das variáveis de entrada da rede;
- Função de Soma $\{\Sigma\}$: Tem por função agregar todos os sinais de entrada e seus respectivos pesos sinápticos ponderados a fim de produzir um valor de potencial de ativação;

- Limiar de Ativação $\{\theta\}$: É a variável que especifica qual será o patamar apropriado para que o resultado produzido pela Função de Soma possa gerar um valor de disparo em direção à saída do neurônio;
- Potencial de Ativação $\{u\}$: É o resultado da diferença do valor gerado entre o Limiar de Ativação e a Função de Soma. Se o valor gerado for positivo, $u \geq 0$, o neurônio produz um potencial excitatório, caso contrário, o potencial será inibitório;
- Função de Ativação $\{g(.)\}$: função que limita a saída do neurônio dentro de um determinado intervalo de valores;
- Saída $\{y\}$: o sinal de saída consiste em um valor final em relação ao conjunto de sinais de entrada.

Estes sete elementos básicos podem ser melhor visualizados através do diagrama da Figura 4.

Figura 4 – Modelo geral do neurônio artificial



Fonte: Adaptado de Boos (2015).

O modo como a rede neural adquire conhecimento é determinado pelo tipo de treinamento da rede e a regra de aprendizado utilizada. Os tipos de treinamento são o supervisionado e o não supervisionado.

No treinamento supervisionado, para cada padrão de entrada utilizado no treinamento, é apresentada à rede a resposta desejada, correspondente à classe à qual pertence o padrão apresentado. No treinamento não supervisionado, os padrões de treinamento são apresentados sem indicação de um valor correspondente para a própria

rede, esta, se encarrega de agrupar em classes de acordo com a semelhança de características entre os padrões de entrada.

As regras de aprendizagem utilizadas no treinamento das redes indicam de que forma os pesos sinápticos serão atualizados para que, ao final do treinamento, a rede classifique corretamente os padrões de entrada. Existem várias regras de aprendizado como, por exemplo, a regra de Hebb, do Perceptron e *Error Backpropagation*, entre outras, que estão descritas na literatura (SILVA; SPATTI; FLAUZINO, 2010).

2.4 MÉTRICAS DE ANÁLISE DE DESEMPENHO

Na avaliação da performance de um teste (ou classificador), diversas métricas são empregadas. Como exemplo, Webber *et al.* (1994) utilizam um gráfico de sensibilidade e especificidade em função do limiar de decisão; Ko e Lin (1998) utilizam o gráfico da sensibilidade e especificidade juntamente com a curva ROC. Outros autores utilizam métricas de desempenho calculadas a partir da sensibilidade e da especificidade, tais como o valor preditivo positivo, utilizado por Aarabi, Grebe e Wallois (2007).

Existem diversas métricas, cada uma priorizando uma determinada condição considerada mais grave ou de maior relevância em detrimento de outras. Uma forma de entender esta situação é se considerar um teste para uma doença grave, por exemplo, o teste para o HIV: é melhor um teste que detecte 90% dos doentes ou que detecte 90% dos sadios, ou seja, é melhor que um doente seja classificado como sadio ou um sadio diagnosticado como doente? Esta e outras perguntas relacionadas possuem implicações éticas muito impactantes e, normalmente, precisam ser analisadas dentro de um contexto subjetivo.

Diferentes campos do conhecimento aplicam com maior frequência uma ou outra métrica para analisar seus testes, devido, principalmente a seus objetivos diferentes. Na ciência da computação, os índices normalmente utilizados são a precisão e a sensibilidade e seus derivados, enquanto que na área médica, normalmente as métricas preferidas são aquelas baseadas em sensibilidade e especificidade (MAZUROWSKI *et al.*, 2008).

As métricas de desempenho podem ser singulares ou duais e podem ou não possuir dependência com a prevalência. Métricas duais são aquelas em que dois índices devem ser analisados conjuntamente para se analisar corretamente o desempenho, em contraste com as

métricas singulares, nas quais apenas um índice é capaz de fornecer as informações desejadas sobre o desempenho do classificador. Normalmente, as métricas singulares são obtidas por operações matemáticas aplicadas na métricas duais.

Neste capítulo, serão demonstradas as principais métricas que poderão ser utilizadas para se avaliar um classificador neural binário. Para isto, as seguintes siglas serão consideradas:

- Padrões epileptiformes (EE);
- Padrões não-epileptiformes (ENE);
- Total de padrões positivos (P) – número de padrões sabidamente epileptiformes;
- Total de padrões negativos (N) – número de padrões sabidamente não-epileptiformes.

2.4.1 Prevalência

Um dos principais índices estatísticos que se deve considerar é a prevalência (PREV) do padrão, ou seja, dentre todos os EE e ENE, quantos EE ocorreram, desta forma, a prevalência é entendida como a probabilidade de ocorrência do padrão dentro da população (Equação 1). É importante salientar que a prevalência depende do conjunto universo utilizado, ou seja, há uma prevalência para o conjunto de testes, uma para o conjunto de validação, outra para o conjunto de avaliação (ou teste), e assim por diante. A prevalência também é chamada de probabilidade pré-teste, ou seja, a probabilidade de um padrão ser epileptiforme, antes da realização do teste (PEWSNER, 2004).

$$PREV = \frac{P}{P + N} \quad (1)$$

Em um exame de EEG de 20 minutos, com 19 canais, há cerca de 100 espículas presentes, em contrapartida, há cerca de 228.000 padrões não-epileptiformes (HARNER, 2009). Isto resulta numa prevalência de 0,00044, valor consideravelmente baixo.

2.4.2 Tabela de Contingência

Ao se utilizar um classificador, é essencial se conhecer seu comportamento estatístico, isto é, qual a probabilidade de acerto e de

erro deste classificador. Isto é feito através do teste do classificador em um conjunto previamente conhecido.

A realidade de cada padrão é conhecida (EE ou ENE), uma vez que o classificador também irá indicar se o padrão é um EE ou um ENE, a comparação entre a realidade e a resposta do classificador para cada padrão recairá em uma de quatro possibilidades:

- Um verdadeiro positivo ocorre quando um EE é corretamente classificado como EE, ou seja, é um EE e o classificador acertou;
- Um verdadeiro negativo ocorre quando um ENE é corretamente classificado como ENE, ou seja, é ENE e o classificador acertou;
- Um falso positivo ocorre quando um ENE é incorretamente classificado como EE, ou seja, é ENE e o classificador errou, ocorrendo um falso alarme;
- Um falso negativo ocorre quando um EE é incorretamente classificado como ENE, ou seja, é EE e o classificador errou, ocorrendo uma perda na classificação.

O falso positivo também conhecido como erro de primeira ordem, ou seja, atribuir uma característica a algo que não a possui, neste caso, classificar em ENE como EE.

O falso negativo é chamado de erro de segunda ordem, ou seja, deixar de atribuir uma característica a algo que a possui, neste caso, liberar um EE, classificando-o como ENE.

Os verdadeiros positivo e negativo são chamados de inferências corretas, uma vez que o classificador acertou na identificação da característica.

Estes índices estatísticos podem ser melhor entendidos através do diagrama apresentado na tabela de contingência 2x2 (Quadro 1).

A partir da aplicação da tabela de contingência e do levantamento dos resultados do teste para cada um dos padrões, as métricas são calculadas, obtendo-se, desta forma, o total de classificações verdadeiro positivo (VP), total de classificações verdadeiro negativo (VN), total de classificações falso positivo (FP) e total de classificações falso negativo (FN). Adicionalmente, também pode-se calcular o total de padrões sabidamente positivos (P) e o total de padrões sabidamente negativos (N).

Quadro 1 – Tabela de contingência

		Resposta esperada (valor de referência)		
		EE	ENE	
		VP	FP	
Resposta do classificador	EE	VP	FP	Resultados positivos (VP + FP)
	ENE	FN	VN	Resultados negativos (FN + VN)
		Padrões positivos (VP + FN)	Padrões negativos (FP + VN)	Total de Padrões (VP + FP + VN + FN)

Fonte: próprio autor

Diante destes possíveis cenários, recorre-se à probabilidade bayesiana, ou seja, probabilidades condicionadas a certezas. Desta forma, os quatro totais (VP, VN, FP e FN) são utilizados para compor outros oito índices, sendo que, quatro estão relacionados ao comportamento do teste diante da apresentação de um evento cuja realidade é conhecida (ou seja, pretende-se inferir o resultado do teste, sendo conhecida a sua realidade) e os outros quatro estão relacionados à probabilidade do teste corroborar a realidade do evento (ou seja, pretende-se inferir sobre a sua realidade, sendo conhecido o resultado do teste).

2.4.3 Inferir o resultado, conhecendo-se o padrão

Quando a realidade do padrão é conhecida, pode-se estimar a probabilidade do teste acertar ou errar a classificação. Ou seja, sabe-se com certeza o tipo de padrão e deseja-se estimar a chance do teste apresentar este resultado. Desta forma, quatro índices são obtidos:

- Sensibilidade (*True Positive Ratio* – TPR);
- Especificidade (*True Negative Rate* – TNR);
- Taxa de Erros (*False Positive Ratio* – FPR);
- Taxa de Perdas (*False Negative Ratio* – FNR).

2.4.3.1 Sensibilidade (*Sensitivity, Recall, True Positive Ratio – TPR*)

A sensibilidade (*True Positive Ratio – TPR*) é a probabilidade do classificador identificar corretamente um EE dentre todos os EE conhecidos (Equação 2). A sensibilidade quantifica a capacidade do teste de evitar falsos negativos, logo, alta sensibilidade implica em um teste que raramente erra um resultado negativo, desta forma, a alta sensibilidade é útil para descartar definitivamente ENE.

$$sens (TPR) = \frac{VP}{P} = \frac{VP}{VP + FN} \quad (2)$$

A sensibilidade pode possuir valores entre zero (sem discriminação) e um (discriminação total).

2.4.3.2 Especificidade (*Specificity, True Negative Ratio – TNR*)

A especificidade (*True Negative Ratio – TNR*) é a probabilidade do classificador identificar corretamente um ENE dentre todos os ENE conhecidos (Equação 3). A especificidade quantifica a capacidade do teste de evitar falsos positivos, logo, alta especificidade implica em um teste que raramente erra um resultado positivo, desta forma, a alta especificidade é útil para confirmar definitivamente EE.

$$espec (TNR) = \frac{VN}{N} = \frac{VN}{VN + FP} \quad (3)$$

Assim como a sensibilidade, a especificidade pode possuir valores entre zero (sem discriminação) e um (discriminação total).

2.4.3.3 Taxa de Erro (*False Positive Ratio – FPR*)

A taxa de erro (*False Positive Ratio – FPR*) é a probabilidade do classificador identificar erroneamente um ENE como sendo um EE, dentre todos ENE conhecidos (Equação 4). Uma vez que a taxa de erro é complementar à especificidade, ela normalmente não é utilizada.

$$taxa\ de\ erro\ (FPR) = \frac{FP}{N} = \frac{FP}{VN + FP} = 1 - espe \quad (4)$$

A taxa de erro pode possuir valores entre zero (discriminação total) e um (sem discriminação).

2.4.3.4 Taxa de Perdas (*False Negative Ratio* – FNR)

A taxa de perdas (*False Negative Ratio* – FNR) é a probabilidade do classificador identificar erroneamente um EE como sendo um ENE, dentre todos os EE conhecidos (Equação 5). Uma vez que a taxa de perdas é complementar à sensibilidade, ela normalmente não é utilizada.

$$taxa\ de\ perdas\ (FNR) = \frac{FN}{P} = \frac{FN}{VP + FN} = 1 - sens \quad (5)$$

A taxa de perdas pode possuir valores entre zero (discriminação total) e um (sem discriminação).

2.4.4 Inferir o Padrão, Conhecendo-se o Resultado

Outros índices são obtidos quando não se sabe a realidade do padrão, neste caso, sabe-se o resultado do teste e pretende-se estimar qual é a chance deste resultado refletir a realidade do padrão. Assim, quatro índices são obtidos:

- Valor Preditivo Positivo (*Positive Predictive Value* – PPV);
- Valor Preditivo Negativo (*Negative Predictive Value* – NPV);
- Taxa de Falsa Descoberta (*False Discovery Ratio* – FDR);
- Taxa de Falsa Omissão (*False Omission Ratio* – FOR).

2.4.4.1 Valor Preditivo Positivo (*Positive Predictive Value* – PPV)

O valor preditivo positivo (*Positive Predictive Value* – PPV), também chamado de precisão positiva e de sensibilidade positiva, é a proporção de resultados positivos que são efetivamente verdadeiros, desta forma, o valor preditivo positivo quantifica a capacidade do teste de, no caso do resultado apontar um EE, acertar (Equação 6). Logo, um alto valor preditivo positivo implica em um teste que quase sempre

acerta um resultado positivo. O valor preditivo positivo não é intrínseco do teste, para se determinar se ele é alto ou baixo, deve-se levar em conta a prevalência do padrão.

$$\text{valor preditivo positivo (PPV)} = \frac{VP}{VP + FP} \quad (6)$$

O valor preditivo positivo pode assumir valores entre zero e um, sendo que zero significa incapacidade de classificar. É importante salientar que a análise da performance da classificação levará em conta a prevalência do padrão.

2.4.4.2 Valor Preditivo Negativo (*Negative Predictive Value* – NPV)

O valor preditivo negativo (*Negative Predictive Value* – NPV), também chamado de precisão negativa e de sensibilidade negativa, é a proporção de resultados negativos que são efetivamente verdadeiros, desta forma, o valor preditivo negativo quantifica a capacidade do teste de, no caso do resultado apontar um ENE, acertar (Equação 7). Logo, alto valor preditivo negativo implica em um teste que quase sempre acerta um resultado negativo. O valor preditivo negativo também não é intrínseco do teste, para se determinar se ele é alto ou baixo, deve-se levar em conta a prevalência do padrão.

$$\text{valor preditivo negativo (NPV)} = \frac{VN}{VN + FN} \quad (7)$$

Similarmente ao PPV, o valor preditivo negativo pode assumir valores entre zero e um, sendo que zero significa incapacidade de classificar e a análise da performance da classificação levará em conta a prevalência do padrão.

2.4.4.3 Taxa de Falsa Descoberta (*False Discovery Ratio* – FDR)

A taxa de falsa descoberta (*False Discovery Ratio* – FDR) é uma forma de se quantificar a proporção de erros de primeira ordem, em comparação com todos os resultados positivos do teste (Equação 8). Uma vez que a taxa de falsa descoberta é complementar ao valor preditivo positivo, ela normalmente não é utilizada.

$$\text{taxa de falsa descoberta (FDR)} = \frac{FP}{VP + FP} \quad (8)$$

2.4.4.4 Taxa de Falsa Omissão (*False Omission Ratio* – FOR)

A taxa de falsa omissão (*False Omission Ratio*) é uma forma de se quantificar a proporção de erros de segunda ordem, em comparação com todos os resultados negativos do teste (Equação 9). Uma vez que a taxa de falsa omissão é complementar ao valor preditivo negativo, ela normalmente não é utilizada.

$$\text{taxa de falsa omissão (FOR)} = \frac{FN}{VN + FN} \quad (9)$$

2.4.5 Índices de Desempenho Derivados dos Anteriores

Os índices de desempenho apresentados anteriormente são índices duais, ou seja, requerem que sejam analisados em conjunto seu índice análogo. Por exemplo, se um classificador binário apresenta sensibilidade de 90% e especificidade de 80% e outro apresenta 80% e 90% para ambos os índices, respectivamente, a decisão a respeito de qual classificador binário é o melhor para a aplicação em questão recai sobre um terceiro índice que sirva de balizador na decisão.

Com base nos índices de desempenho apresentados anteriormente, em especial, sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo, calculam-se outros índices de desempenho, dentre os quais destacam-se:

- Eficiência (*Accuracy*);
- Razão de verossimilhança (*Likelihood Ratio* – LR);
- *Diagnostics Odds Ratio* – DOR;
- Valor F (*F₁ score*);
- Valor G (*G score*);
- Coeficiente de correlação de Matthews e correlação aproximada;
- Índice de Youden (*Informedness*) e *Markedness*.

O Quadro 2 apresenta um resumo dos principais índices estatísticos apresentados.

Quadro 2 – Distribuição visual dos principais índices estatísticos.

População		Resposta esperada	(valor de referência)	Prevalência $\frac{EE}{EE + ENE}$	
		EE	ENE		
Resposta do classificador	EE	VP	FP	$\frac{PPV}{VP + FP}$	$\frac{FDR}{FP + FP}$
	ENE	FN	VN	$\frac{FOR}{FN + FN}$	$\frac{NPV}{VN + FN}$
Eficiência $\frac{VP + VN}{população}$		$\frac{sens}{VP + FN}$	$\frac{FPR}{FN + FP}$	$\frac{LR_{+}}{1 - espe}$	$\frac{DOR}{\frac{LR_{+}}{LR_{-}}}$
		$\frac{FNR}{VP + FN}$	$\frac{espe}{VN + FP}$	$\frac{LR_{-}}{1 - sens}$	

Fonte: próprio autor.

2.4.5.1 Eficiência

A eficiência é a proporção de acertos (tanto VP quanto VN) dentre todos os padrões analisados (Equação 10).

$$eficiência = \frac{VP + VN}{VP + VN + FP + FN} \quad (10)$$

A eficiência pode ser expressa em termos de sensibilidade e especificidade se a prevalência é conhecida (Equação 11).

$$eficiência = sens \cdot prev + espec \cdot (1 - prev) \quad (11)$$

Outra forma de se medir a performance do classificador é através da eficiência balanceada (Equação 12), que evita falhas de percepção de performance causada por desbalanços devido à baixa prevalência (BRODERSEN *et al.*, 2010).

$$efic. bal. = \frac{0,5 \cdot VP}{VP + FN} + \frac{0,5 \cdot VN}{VN + FP} \quad (12)$$

Tanto a eficiência, quanto a eficiência balanceada variam de zero (sem discriminação) a um (discriminação perfeita).

2.4.5.2 Razão de Verossimilhança (*Likelihood Ratio* – LR)

A primeira referência à razão de verossimilhança (*Likelihood Ratio* – LR) data de um simpósio em teoria da informação de 1954. A LR faz uso da sensibilidade e da especificidade para avaliar a performance de um teste. Existem dois índices:

- Razão de Verossimilhança Positiva (*Positive Likelihood Ratio* – LR_+);
- Razão de Verossimilhança Negativa (*Negative Likelihood Ratio* – LR_-).

A razão de verossimilhança positiva (*Positive Likelihood Ratio* – LR_+) pode ser entendida como uma medida da probabilidade de um EE ser classificado como EE dividida pela probabilidade de um ENE também ser classificado como EE (Equação 13).

$$LR_+ = \frac{sens}{1 - espe} \quad (13)$$

A razão também pode ser obtida utilizando-se apenas os totais da tabela de contingência (Equação 14).

$$LR_+ = \frac{VP \cdot (VN + FP)}{FP \cdot (VP + FN)} \quad (14)$$

A razão de verossimilhança negativa (*Negative Likelihood Ratio* – LR_-) pode ser entendida como uma medida da probabilidade de um EE ser classificado como ENE dividida pela probabilidade de um ENE também ser classificado como ENE (Equação 15).

$$LR_- = \frac{1 - sens}{espe} \quad (15)$$

A razão pode ser obtida utilizando-se apenas os totais da tabela de contingência (Equação 16).

$$LR_- = \frac{FN \cdot (VN + FP)}{VN \cdot (VP + FN)} \quad (16)$$

2.4.5.3 Diagnostics Odds Ratio – DOR

A *Diagnostics Odds Ratio* (DOR) é definida como sendo a razão da probabilidade do teste acusar positivo dado que é EE pela probabilidade do teste acusar positivo dado que é ENE (Equação 17). A DOR é independente da prevalência e apresenta uma forma de mensurar a performance do classificador através de apenas um índice.

$$DOR = \frac{VP/FP}{FN/VN} \quad (17)$$

A DOR também pode ser expressa em termos de sensibilidade e especificidade (Equação 18), *PPV* e *NPV* (Equação 19) e LR_+ e LR_- (Equação 20).

$$DOR = \frac{sens \cdot espe}{(1 - sens) \cdot (1 - espe)} \quad (18)$$

$$DOR = \frac{PPV \cdot NPV}{(1 - PPV) \cdot (1 - NPV)} \quad (19)$$

$$DOR = \frac{LR_+}{LR_-} \quad (20)$$

A DOR é um índice que varia de zero até o infinito. Se o DOR for igual a um, o teste não é capaz de discriminar corretamente e é, portanto, inútil. Valores maiores que um indicam que o teste tem capacidade de discriminar corretamente, com maior performance quanto maior for o índice. De modo análogo, quanto mais próximo do zero, maior a performance do teste em errar, logo, o teste pode ser corrigido para acertar apenas invertendo-se a sua resposta lógica (GLAS *et al.*, 2003).

2.4.5.4 Valor F (*F₁ score*)

O valor F (*F₁ score* ou *F-measure*) é uma medida da performance de um classificador, calculado pela média harmônica da precisão positiva (PPV) e da sensibilidade (Equação 21). Os valores possíveis variam de zero (sem discriminação) a um (discriminação perfeita).

$$F_1 = \frac{2}{\frac{1}{sens} + \frac{1}{PPV}} = 2 \cdot \frac{sens \cdot PPV}{sens + PPV} \quad (21)$$

2.4.5.5 Valor G (*G score*)

O valor G (*G score*), que, assim como o valor F, é uma medida da performance de um classificador utilizando a precisão positiva (PPV) e da sensibilidade, entretanto, o cálculo leva em consideração a média geométrica (Equação 22). Da mesma forma, os valores possíveis variam de zero (sem discriminação) a um (discriminação perfeita).

$$G = \sqrt{sens \cdot PPV} \quad (22)$$

2.4.5.6 Coeficiente de Correlação de Matthews

O coeficiente de correlação de Matthews (*Matthews Correlation Coefficient – MCC*), calculado através da Equação 23, foi introduzido por Brian W. Matthews no seu trabalho de 1975, e é muito utilizado em ciências da computação como métrica de desempenho para aprendizado de máquina (MATTHEWS, 1975).

$$MCC = \frac{VP \cdot VN - FP \cdot FN}{\sqrt{(VP + FP) \cdot (VP + FN) \cdot (VN + FP) \cdot (VN + FN)}} \quad (23)$$

O MCC é um coeficiente de correlação entre o valor observado e o valor previsto, retornando um valor entre -1 e +1. Um MCC de +1 representa a classificação perfeita, enquanto que o valor 0 representa um classificador incapaz de predição diferente de aleatória. Da mesma forma que o *Diagnostics Odds Ratio*, quanto mais próximo de -1, mais especializado em errar o classificar é, e seu resultado pode ser melhorado através da inversão da resposta desejada do teste.

2.4.5.7 Correlação Aproximada

Um problema com o MCC pode ocorrer quando os dois termos de qualquer uma das somas é zero. A correlação aproximada (*Approximate Correlation* – AC) e a probabilidade condicional média (*Average Conditional Probability* – ACP) foram desenvolvidas por (BURSET; GUIGÓ, 1996) para contornar esta situação (Equação 24).

$$ACP = \frac{1}{4} \cdot \left(\frac{VP}{VP + FN} + \frac{VP}{VP + FP} + \frac{VN}{VN + FP} + \frac{VN}{VN + FN} \right) \quad (24)$$

A ACP apresenta valores entre 0 e 1, entretanto, normalmente, utiliza-se a AC (Equação 25) como forma de escalonamento da ACP para obtenção de valores entre -1 e 1, sendo 1 a classificação perfeita, 0 a classificação aleatória e -1 a classificação perfeitamente invertida.

$$AC = 2 \cdot (ACP - 0,5) \quad (25)$$

2.4.5.8 Índice de Youden (*Informedness*) e *Markedness*

O índice de Youden, índice J ou *informedness* (Equação 26), foi introduzido por William J. Youden em 1950 (YOUTEN, 1950) e quantifica o quanto informado sobre uma certa condição o classificador está e, também especifica a probabilidade de que a classificação esteja informada em relação à condição (POWERS, 2011).

$$J = sens + espe - 1 \quad (26)$$

O Índice de Youden possui valores entre -1 e 1, sendo que 1 representa o classificador perfeito e 0 representa um classificador que fornece a mesma proporção de resultados positivos para ambos os grupos (sabidamente positivos e sabidamente negativos), ou seja, não possui capacidade de discriminação, e -1, um classificador cuja predição é perfeitamente invertida.

O índice pondera resultados falsos positivos e falsos negativos da mesma forma, logo, uma análise de risco pode ser necessária para se escolher entre dois classificadores com mesmo índice e proporções de FP e FN distintas.


O índice *markedness* (Equação 27) quantifica o quanto uma certa condição está marcada pelo classificador e, também especifica a probabilidade de que a classificação esteja marcada em relação à condição pelo classificador (POWERS, 2011).

$$\textit{markedness} = PPV + NPV - 1 \quad (27)$$

2.4.6 Comportamento Sensibilidade vs. Especificidade

Através da alteração do limiar de decisão (nível de *threshold* ou ponto de corte) pode-se descrever uma função da sensibilidade e outra da especificidade em função do limiar de decisão. O gráfico destas duas funções, quando traçadas sobrepostas, assemelha-se ao da Figura 5.

Figura 5 – Comportamento da sensibilidade (linha sólida) e da especificidade (linha tracejada) em função do limiar de decisão (*threshold*).




Fonte: próprio autor.

No gráfico, a sensibilidade (linha azul contínua) decresce com o aumento do limiar de decisão, enquanto que a especificidade (linha vermelha tracejada) cresce com o aumento do limiar de decisão.

2.4.6.1 Taxa de Erro Igual (*Equal Error Ratio – EER*)

Um dos índices estatísticos mais utilizados quando se analisa o gráfico da sensibilidade e da especificidade em função do limiar de decisão é a taxa de erro igual (*Equal Error Ratio – EER*), definida pelo ponto de cruzamento entre as linhas de sensibilidade e de especificidade (Figura 6).

Figura 6 – Ponto da taxa de erro igual (EER) obtida através do gráfico da sensibilidade e especificidade em função do limiar de decisão (*threshold*).



Fonte: próprio autor.


2.4.6.2 SnSpO e SpSnO

Há momentos em que o usuário deseja um classificador que apresente a máxima especificidade ou a máxima sensibilidade possível. Neste caso, é fundamental utilizar-se os índices SnSpO (*Sensitivity to Specificity Equal One*) e SpSnO (*Specificity to Sensibility Equal One*). Estes índices podem ser obtido a partir do gráfico de sensibilidade e especificidade em função do *threshold*, escolhendo-se o ponto em que um dos índices seja 100% e o outro índice seja máximo. Outra forma de identificar este índice é através da análise direta da curva ROC.

2.4.7 Análise ROC

Outra forma de representar o gráfico da sensibilidade e da especificidade é através da curva ROC (*Receiver Operating Characteristic*). A curva ROC permite visualizar os valores de sensibilidade e de especificidade em um gráfico cartesiano, auxiliando visualmente a seleção de classificadores através do seu desempenho (FAWCETT, 2006).

A análise ROC faz uso da curva ROC, uma curva traçada sob um ar de eixos cartesianos, contendo indicando os valores da fração de falsos positivos ($1 - \text{especificidade}$), no eixo das abscissas e os valores da fração de verdadeiros positivos (sensibilidade) no eixo das ordenadas. A Figura 7 apresenta uma curva ROC hipotética. O ponto marcado pela seta indica o ponto ideal do classificador, logo, quanto mais próxima a curva estiver deste ponto, maior será a capacidade de discriminação do classificador. A região triangular hachurada indica um classificador que classifica aleatoriamente os padrões (%VP menor ou igual ao %FP). A semi-diagonal pontilhada apresenta os valores em que a sensibilidade e a especificidade são iguais, logo, o ponto da curva que cruza essa semi-diagonal é o ponto da taxa de erro igual (EER) (SOVIERZOSKI, 2009).



Fonte: Modificado de Sovierzoski (2009).

Outro índice que é extraído da curva ROC é a área sobre a curva (*Area Under Curve – AUC*). O índice é obtido através do cálculo (por

Soma de Riemann) da área da curva no gráfico. A área pode ser calculada através de duas abordagens: otimista e pessimista.

Na abordagem otimista assume-se pontos de operação que aumentam o valor do índice AUC, sendo considerada uma abordagem irreal, normalmente sendo substituída por uma interpolação linear entre os pontos da curva ROC. Na abordagem pessimista, o mesmo valor de sensibilidade do ponto inferior da curva ROC é utilizado até o próximo ponto da curva para a direita, apresentado uma abordagem mais realista da operação da curva ROC (SOVIERZOSKI, 2009).

Diversas curvas distintas podem apresentar o mesmo valor AUC, portanto, o índice AUC deve sempre ser avaliado em conjunto com outros índices estatísticos.

3 MATERIAIS E MÉTODOS

Este estudo trata-se de um estudo de tipologia exploratório-descriptivo, de acordo com os objetivos descritos nesta pesquisa. Quanto a natureza da pesquisa, classifica-se como natureza aplicada, pois têm por objetivo gerar conhecimentos para aplicação prática na resolução de problemas específicos, por meio de levantamento bibliográfico, e uso de uma base de dados. A pesquisa é de abordagem quantitativa, pois os números serão traduzidos em informações. O método de coleta de dados baseou-se na utilização de registros de EEG de pacientes comprovadamente epiléticos obtidos de um banco de dados com as informações fornecidas pelo Centro de Epilepsia de Santa Catarina (CEPESC) da UFSC.

O desenvolvimento dessa pesquisa foi realizado no Laboratório de Informática em Saúde nas dependências do Instituto Engenharia Biomédica (IEB-UFSC). O IEB-UFSC tem como missão promover ensino, pesquisa e extensão na área de Engenharia Biomédica. Os trabalhos neste laboratório iniciaram com processamento e análise de sinais de EEG em 1998, e concentram-se basicamente em três linhas de pesquisa: identificação de eventos epileptiformes, identificação de padrões característicos do sono e avaliação da profundidade anestésica.

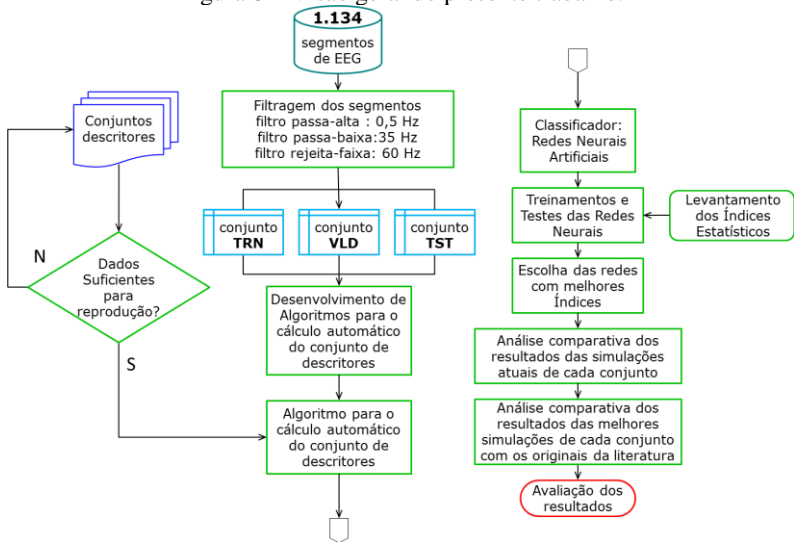
Duas teses desenvolvidas nesse laboratório, Pereira (2003) e Sovierzoski (2009), propuseram a utilização de descritores morfológicos para o auxílio da identificação de padrões epileptiformes em sinais de EEG.

Pereira (2003) em sua tese de doutorado realizou estudos das características de segmentos de sinais com espículas, atividade de fundo normal, ondas alfa, ruídos e piscadas. Foram definidos 45 descritores, classificados em seis grupos de acordo com a grandeza envolvida: amplitude, duração, ângulo, distância, dados estatísticos e entropia. Esse trabalho obteve desempenho médio (entre sensibilidade, especificidade, VPP, VPN) de 73,2 %.

Sovierzoski (2009) em sua tese de doutorado propôs uma avaliação de descritores morfológicos, apresentava 30 descritores morfológicos, baseados no trabalho de Pereira (2003). O autor utilizava um classificador neural artificial para realizar a avaliação dos descritores morfológicos. Essa metodologia obteve índices de sensibilidade de 91,92%, especificidade de 91,09%, valor preditivo positivo de 91,00% e valor preditivo negativo de 92,00%, alcançando desempenho médio de 91,32%.

Nesta sessão serão apresentados o banco de dados, os filtros utilizados para o processamento dos sinais do banco de dados, Os conjuntos dos descritores, a arquitetura e as topologias do classificador binário utilizado, o *software* e as metodologias para extração dos descritores morfológicos e os índices estatísticos que serão utilizados para avaliar o desempenho dos descritores. Uma visão geral da metodologia proposta encontra-se na Figura 8.

Figura 8 – Visão geral do presente trabalho.



Fonte: próprio autor.

Foi realizada uma revisão bibliográfica de trabalhos envolvendo descritores morfológicos na detecção de padrões epileptiformes. Na sequência, foi realizada uma pré-seleção dos trabalhos que contavam com dados suficientes para sua reprodução nesta dissertação; visto que havia a possibilidade de realizar a reprodução de parte destes estudos com fidedignidade escolheu-se o banco de dados com registros de EEGs, neste banco foi realizado um pré-processamento e o mesmo foi dividido em três conjuntos, o de treinamento, o de validação e o de teste. Esses dados passam pelos algoritmos desenvolvidos para realizar o cálculo automático dos conjuntos de descritores morfológicos.

Os conjuntos de descritores foram utilizados como entrada do classificador neural. Cada conjunto foi treinado pelo classificador neural

e testado e com isso foi possível a realização do cálculo dos índices estatísticos.

Com todas as redes treinadas e testadas com seus respectivos índices estatísticos é realizada então, a análise comparativa dos resultados melhores de cada conjunto e depois uma segunda análise entre os resultados deste trabalho com os originais apresentados na literatura. E com isso, poder afirmar se os resultados analisados possuem características promissoras ou não.


3.1 BASE DE DADOS – SINAIS DE EEG

Por se tratar de uma pesquisa que envolve o manejo de dados de seres humanos foi necessária a aprovação de um projeto no Comitê de Ética em Pesquisa com Seres Humanos (CEPSH) da UFSC. Como este trabalho é uma parte do projeto “Sistema Inteligente para processar padrões epileptiformes em sinais de EEG de longa duração”, já aprovado pelo CEPSH, fez-se necessária apenas a realização uma emenda ao projeto. A emenda foi aprovada em 24 de abril de 2014 (parecer número 711.454).

A base de dados utilizada neste trabalho é composta por 17 registros de EEG de pacientes comprovadamente epiléticos, fornecidos pelo Centro de Epilepsia de Santa Catarina (CEPESC) no Serviço de Neurologia do HU/UFSC. Os registros foram adquiridos pelo sistema CEEgraph Vision EEG® com frequência de amostragem de 512 Hz, utilizando 32 eletrodos dispostos em montagem referencial com referência no eletrodo Pz. Os sinais foram condicionados por um filtro passa-alta com frequência de corte em 0,5 Hz, um filtro passa-baixa com frequência de corte em 35 Hz e um filtro rejeita-faixa com frequência de corte em 60 Hz.

Para as simulações realizadas neste trabalho foram extraídos 1.134 segmentos de sinal de EEG da base de dados contendo os padrões ilustrados na Figura 9: espículas (a), piscadas palpebrais (b), atividade normal de fundo (c) e artefatos ruidosos (d). Os segmentos de sinal foram divididos em três conjuntos de padrões para implementar e testar os conjuntos de descritores utilizando redes neurais artificiais. A quantidade de padrões em cada um dos três conjuntos está detalhada na Tabela 2.

Figura 9 – Segmentos de sinal de EEG do banco utilizado contendo (a) espículas, (b) piscadas palpebrais, (c) atividade normal de fundo e (d) ruídos.



Fonte: próprio autor.

Tabela 2 – Composição dos conjuntos de padrões utilizados nas simulações.

Conjunto de padrões	Ocorrência de paroxismos (EE)	Sem ocorrência de paroxismos (ENE)
Treinamento	118	118
Validação	118	118
Teste	241	421
Total de Padrões	477	657

3.2 CONJUNTO DE DESCRITORES

Em complementação à fundamentação teórica apresentada nos itens anteriores, esta seção dedica-se à apresentação de uma tabela comparativa de metodologias e sistemas descritos na literatura do estado da arte no qual se insere este trabalho (Tabela 3).

Davey *et al.* (1989), Jones e Dingle (1989), Dingle *et al.* (1993) e Jones e Dingle (1996) utilizaram contexto espacial entre canais adjacentes e utilizaram registro de EEG contínuo, sendo assim, não foi possível sua reprodução pois o banco utilizado neste trabalho é composto por segmentos de sinal de três segundos, não estando disponível o registro corrido nem seu contexto espacial.

Acir *et al.* (2005) utilizam os descritores de Gotman e Gloor (1976) como entrada de uma rede neural de pré-classificação, entretanto, a rede neural de pós-classificação não utiliza descritores morfológicos, analisando, apenas, o sinal de EEG janelado em torno do pico.

De forma mais comum, os autores não citam a forma de extrações dos descritores, informação necessária à sua reprodução, por exemplo, Eberhart, Dobbins e Webber (1989a), Eberhart, Dobbins e Webber (1989b) e Eberhart, Dobbins e Webber (1989c) citam o uso de descritores, entretanto, não especificam o método de cálculo para sua obtenção. Outro exemplo é o trabalho de Aarabi, Grebe e Wallois (2007) que cita 50 descritores, entretanto, apresenta apenas 28 descritores, sendo que os outros 22 descritores não são mais tratados no decorrer do trabalho.

Analizando os estudos fez-se necessária a exclusão de 36 deles por não apresentarem informações suficientes sobre o método de extração dos descritores ou os descritores apresentados eram um subconjunto dos descritores apresentados em um trabalho posterior. A quantidade de descritores e os conjuntos que serão implementados e analisados no presente trabalho são apresentados na Tabela 3.

Tabela 3 – Relação dos autores e seus descritores morfológicos

Conjunto	Número de descritores
Hjorth (1970)	3
Frost (1979)	6
Gotman (1980)	6
Ktonas <i>et al.</i> (1981)	10
Lemieux e Blume (1983)	16
Pereira (2003)	43
Sovierzoski (2009)	30

3.2.1 Hjorth (1970)

Segundo Hjorth (1970), um sinal de EEG dentro de uma época pode ser expresso como uma função do tempo $f(t)$, que, pela aplicação da transformada de Fourier, pode ser convertida para o domínio da frequência $F(\omega)$. A fase do sinal é eliminada pela multiplicação de $F(\omega)$ pelo seu conjugado $F^*(\omega)$, resultando no espectro de potência $S(\omega)$ (Equação 30).

$$S(\omega) = F(\omega) \cdot F^*(\omega) \quad (28)$$

A descrição em frequência obtida através da transformada de Fourier é sempre simétrica em relação ao eixo das ordenadas, logo, numa abordagem estatística do formato da distribuição espectral, todos os momentos de ordem ímpar serão iguais a zero, não havendo, portanto, informação sobre a média (momento de ordem 1) ou sobre a assimetria (momento de ordem 3) da distribuição. A definição geral para um momento m de ordem n é dada pela Equação 31.

$$m_n = \int_{-\infty}^{\infty} \omega^n \cdot S(\omega) \cdot d\omega \quad (29)$$

A Quadro 3 apresenta os principais momentos estatísticos associados à distribuição espectral e sua correlação com as operações nas funções temporais.

Quadro 3 – Principais momentos estatísticos associados à distribuição espectral e a correlação com as operações nas funções temporais.


Momento Espectral	Definição do Parâmetro	Operação no Tempo
m_0	$m_0 = \text{atividade} = \sigma_a^2$	$f(t)$
$m_1 = 0$	-	-
m_2	$\sqrt{m_2/m_0} = \text{mobilidade} = \sigma_d/\sigma_a$	
$m_3 = 0$	-	-
m_4	$\frac{\sqrt{m_4/m_2}}{\sqrt{m_2/m_0}} = \text{complexidade} = \frac{\sigma_{dd}/\sigma_d}{\sigma_d/\sigma_a}$	$\frac{d^2 f(t)}{dt^2}$
$m_5 = 0$	-	-
m_6, m_8, \dots
m_0	$m_0 = \text{atividade} = \sigma_a^2$	$f(t)$

Modificado de Hjorth (1970).

A Figura 10, apresenta três descritores associados à distribuição espectral: atividade, mobilidade e complexidade.

A atividade é calculada pela variância (desvio padrão ao quadrado) da amplitude. A mobilidade é calculada pela razão entre o desvio padrão da inclinação e o desvio padrão da amplitude. A complexidade fornece uma medida do quando o formato da distribuição difere de uma onda senoidal.

Figura 10 – Atividade, mobilidade e complexidade, e sua correlação com os domínio do tempo e da frequência.



Fonte: Modificado de Hjorth (1970).

3.2.2 Frost (1979)

Frost (1979) desenvolveu um sistema automatizado para detecção de espículas baseado em um microprocessador Z80 (Zilog) com 16 KB de RAM.


O sinal de EEG foi processado por um filtro analógico passa-faixas com banda de passagem entre 0,5 Hz e 42 Hz e, logo após, foi amostrado por um conversor A/D de 8 bits com taxa de amostragem de 250 Hz. O sistema analisava os dados amostrados e o resultado da análise era enviado para um computador para armazenamento e visualização dos resultados.

O sistema operacional executado no microprocessador carregava um programa armazenado na RAM, composto de um algoritmo de análise em dois níveis. Os dados convertidos pelos A/D eram enviados para o primeiro nível de análise, onde eram armazenados em um buffer circular de 250 bytes, capaz de armazenar um segundo de sinal.

Os autores definiram padrões epileptiformes como sinais caracterizados por uma componente de onda aguda ou um pico altamente curvado, indicado na Figura 11 pela letra S. O ponto de início

desta forma de onda é determinado pelo ponto M. Em algumas situações, o ponto M aparenta estar no pico de uma rápida deflexão de polaridade oposta, em outros momentos, o ponto aparenta estar no início da atividade de fundo do EEG. De modo análogo, o ponto de término do padrão P, pode ocorrer no pico de uma terceira deflexão ou no término de uma rápida descida. Portanto, mesmo que um padrão epileptiforme seja monofásico, bifásico ou trifásico, a componente significativa para a classificação do padrão pode ser determinada pelos pontos M, S e P.

Figura 11 – Pontos e descritores utilizados por Frost (1979).



Fonte: próprio autor.

Pela característica da espícula, espera-se uma deflexão MS seguida imediatamente por uma outra deflexão SP de inclinação similar, logo, o método matemático mais indicado para detectar esta característica é a segunda derivada do sinal de EEG. Desta forma, os padrões epileptiformes podem ser identificados pela comparação do valor instantâneo da segunda derivada do sinal de EEG com um limiar baseado numa média móvel do sinal.

Segundo os autores, embora a forma mais simples de se calcular a segunda derivada do sinal seja obtida pela subtração do valor no ponto pelo valor do ponto anterior e depois subtraindo-se este resultado por uma diferença similar baseada nos dois pontos anteriores (Equação 28), o resultado final pode ser comprometido pela presença de componentes de ruído de baixa amplitude. Consequentemente, foi utilizado um método de amortização destas componentes, baseado numa aproximação da derivada segunda através do uso de todos os pontos intermediários, conforme a Equação 29, com N_5 sendo a amostra atual, N_4 , a amostra anterior e assim, sucessivamente.

$$D = \frac{(N_5 - N_4) + (N_4 - N_3)}{2} - \frac{(N_3 - N_2) + (N_2 - N_1)}{2} \quad (30)$$

$$D = \frac{N_5 - 2 \cdot N_3 + N_1}{2} \quad (31)$$

O valor D é proporcional à agudeza do sinal e foi comparado com um limiar para determinar se o pico pertencia a um possível padrão epileptiforme. Este limiar foi obtido pelos autores através de métodos empíricos.

Se o valor D calculado for maior que o limiar, o ponto é considerado como um padrão em potencial, então, um segundo de sinal antes do ponto e um segundo de sinal após o ponto são transferidos para a análise de segunda ordem, para ser armazenados para análise subsequente.

A análise de segunda ordem é realizada no bloco, de modo a identificar os pontos M, S e P. Inicialmente, o *buffer* é escaneado em busca do máximo valor D na janela de 48ms em torno do ponto detectado pela análise de primeira ordem.

O ponto M era localizado no próximo pico de polaridade reversa a do ponto S. O segmento MS era reescaneado, se a inclinação for menor que 1,2 $\mu\text{V}/\text{ms}$, o ponto era redefinido como sendo o novo ponto M e o processo era finalizado.

O ponto P é determinado de forma análoga ao ponto M, entretanto, na direção oposta. Se qualquer um dos pontos não puder ser determinado através deste processo, o padrão é rejeitado e desconsiderado como sendo uma espícula em potencial.

A amplitude do padrão é definida pela máxima amplitude da componente MSP. A duração do padrão pode ser considerada como

sendo a diferença temporal entre os pontos M e P. Duas medidas de amplitude são definidas A1 para a fase inicial e A2 para a fase final; a maior destas amplitudes é tida como a amplitude do padrão. Para eliminar as configurações de amplitude não significativa, ambos A1 e A2 devem exceder 10 μV e A1 ou A2 deve exceder 20 μV .

3.2.3 Gotman (1980)

Gotman e Gloor (1976) apresentam um método para determinar o início e o final de uma onda. Primeiro os autores definem segmento como a seção entre dois extremos consecutivos na amplitude de um sinal, sendo caracterizado pela duração, amplitude e direção. Uma vez que a direção entre dois segmentos consecutivos alterna, os autores agrupam segmentos em sequências para separar cada meia onda. Cada sequência é formada por todos os segmentos cuja amplitude seja menor que a amplitude do segmento anterior. A Figura 12 apresenta um exemplo de determinação de sequências.



Fonte: Modificado de Gotman e Gloor (1976).

No exemplo da Figura 12(b), considera-se o segmento AB como segmento inicial da sequência. Este segmento possui direção de subida, desta forma, farão parte da sequência todos os segmentos de descida cuja amplitude seja menor que a amplitude do próximo segmento de subida. Uma vez que o segmento de descida incluso na sequência possuirá amplitude menor que o a do segmento de subida seguinte, garante-se que a sequência não diminui sua amplitude entre dois segmentos consecutivos, resultado no gráfico da Figura 12(c).

Gotman em 1980 utilizou sinais de EEG de pacientes do Montreal Neurological Hospital, separando-os em dois grupos: grupo de eventos epileptiformes unilaterais (UN – 26 pacientes) e grupo de eventos epileptiformes bilaterais (BL – 23 pacientes). O grupo UN

possuía 31 registros, sendo que 21 pacientes foram registrados apenas uma vez e cinco pacientes foram registrados duas vezes; enquanto que o grupo BL possuía 29 registros, sendo que 17 pacientes foram registrados apenas uma vez e seis pacientes foram registrados duas vezes. Os registros foram tomados em três diferentes montagens, dependendo da condição do paciente: sphenoidal-parasagittal, sphenoidal-temporal e parasagittal e temporal anteroposterior.

Os registros foram analisados e classificados de acordo com a quantidade de padrões epileptiformes, sendo que somente os registros dos canais contendo atividade epiléptica suficiente foram conservados. Desta forma, a base de dados foi formada por registros com duração entre 3min e 5h, totalizando 73 canais no grupo UN, com média de 31 padrões epileptiformes por canal e, no grupo BL, 144 canais no hemisfério com anormalidade primária (média de 49 padrões epileptiformes por canal) e 100 canais no hemisfério com anormalidade secundária (média de 22 padrões epileptiformes por canal).


Os registros foram processados para identificação automática de espículas e ondas agudas através dos métodos descritos em Gotman e Gloor (1976) e Gotman *et al.* (1979). Os padrões epileptiformes identificados pelos algoritmos foram analisados por especialistas para eliminação de falsos positivos.

Os padrões foram processados para determinar os pontos de início da primeira meia onda (A) e de final da segunda meia onda (E) através do método de segmentos de sequências de Gotman e Gloor (1976); o ponto B marca a metade da duração da primeira meia onda; e o ponto D marca a metade da duração da segunda meia onda.

O autor define os descritores (referenciados no trabalho pela terminologia “medições”) baseados nestes cinco pontos, de acordo com a amplitude, duração e inclinação em cada meia onda. A Figura 13 ilustra os cinco pontos utilizados e os descritores.

A amplitude da primeira meia onda é obtida pela diferença entre a amplitude do pico e a amplitude do início da meia onda (C-A) e sua duração pela diferença entre o tempo de ocorrência do pico e do início da meia onda. De modo análogo, se obtém a amplitude da segunda meia onda e sua duração através da diferença entre os pontos (E-C). A inclinação da primeira meia onda é obtida pela inclinação da reta que passa pelos pontos B e C, através do cálculo da amplitude C-B dividida pela duração C-B, e a da segunda meia onda, pela reta que passa pelos pontos C e D.

Figura 13 – Descritores definidos por Gotman (1980).



Fonte: próprio autor.

Gotman e Wang (1991) introduziram o conceito de “detecção de espículas dependente do estado”. Os autores propuseram que o sinal de EEG fosse analisado juntamente com o contexto do paciente. Neste sentido, os autores definiram cinco estados de atividade que deveriam ser identificáveis a partir do próprio sinal de EEG: alerta ativo, alerta em repouso, EEG fásico, EEG dessincronizado e sono de ondas lentas.

O estado de alerta ativo apresenta piscadas palpebrais frequentes e artefatos de movimento, com possível atividade de EMG (eletromiograma). O estado de alerta em repouso apresenta piscadas palpebrais e movimento oculares ocasionais, atividade de EMG baixa ou ausente e não apresenta artefatos de movimento. O EEG fásico é característico do estágio 2 do sono, porém pode abranger parte do estágio 2, e é caracterizado por grande presença de ondas teta e atividade fásica. O EEG dessincronizado ocorre nas situações de sonolência (estágio 1 do sono) e no estágio REM (*Rapid Eye Movement*). O sono de ondas curtas é composto pela maior parte do estágio 2 e do estágio 4, possuindo atividade delta predominante.

O estado de alerta do paciente era determinado pela análise do conteúdo espectral dos sinais. Desta forma, através da determinação do estado de alerta do paciente, o sistema permitia a eliminação seletiva de uma determinada fonte de ruído, objetivando minimizar a ocorrência de

falsos positivos nas espículas. No ano seguinte, Gotman e Wang (1992) publicaram um artigo detalhando os resultados do sistema.

3.2.4 Ktonas *et al.* (1981)

Ktonas e Smith (1974) utilizaram uma base de dados de sinais de EEG de três pacientes comprovadamente epiléticos. Os sinais foram digitalizados com frequência de amostragem de 1 kHz e com filtro analógico passa-baixas (frequência de corte de 100 Hz e atenuação de 18 dB/oitava) para redução do efeito de *aliasing*.

Os sinais digitalizados foram processados, sendo inicialmente filtrados através de um filtro passa-baixa (frequência de corte de 50 Hz e atenuação de 17 dB/oitava) para eliminação de componentes de frequência de baixa amplitude e alta frequência que contribuiriam com ruído na primeira derivada do sinal. O filtro manteve as características de formato e amplitude das espículas, exceto por uma pequena redução na amplitude. Após, os sinais foram derivados e armazenados para análise.

Em cada sinal, padrões epileptiformes bem definidos foram selecionados e processados para a obtenção de seis descritores morfológicos (referenciados no trabalho pela terminologia parâmetros), apresentados na Quadro 4.

Quadro 4 – Descritores utilizados por Ktonas e Smith (1974).

Símbolo	Descrição
S_1	Máxima inclinação antes do pico
S_2	Máxima inclinação depois do pico
S_3	Duração entre S_1 e o pico
S_4	Duração entre o pico e S_2
S_5	Soma de S_3 e S_4 (agudeza)
S_6	Duração de espículas que exibam um formato triangular bem definido

Fonte: próprio autor


O descritor S_5 é inversamente proporcional a agudeza do sinal, pois, quanto mais pronunciado for o pico, menor será o valor dos descritores S_3 e S_4 .

Para a determinação da duração da espícula, é necessário se definir uma linha de base para se realizar a medição, uma vez que nem sempre é possível identificar com clareza os pontos de início e final do

padrão, este descritor foi somente calculado nos casos em que estes pontos pudessem ser encontrados.

O descritor S_6 foi proposto como sendo uma medida da duração dos padrões que possuíssem um formato triangular bem definido. Os autores calcularam o valor deste descritor de duas formas: num primeiro momento, o descritor foi denominado S_6 e foi definido como sendo a diferença temporal entre os pontos P_1 e P_2 (Figura 14), e, num segundo momento, denominado de S'_6 e calculado como sendo a diferença temporal entre o ponto P_1 e o ponto marcado no descritor S_2 (máxima inclinação depois do pico).

Figura 14 – Pontos P_1 e P_2 apresentados por Ktonas e Smith (1974).



Fonte: Modificado de Ktonas e Smith (1974).

Em um trabalho posterior, Ktonas *et al.* (1981) selecionaram espículas bem definidas e ondas agudas de dois pacientes comprovadamente epiléticos (meninas pré-adolescentes alertas) no *EEG and Clinical Neurophysiology Laboratory* do Hermann Hospital em Houston (Estados Unidos). Uma das pacientes apresentava atividade polifásica, principalmente nas regiões frontal direita, central e parietal. Desta paciente, foi obtido um registro com 10 minutos de duração, apresentado 170 espículas e 75 ondas agudas. A outra paciente apresentava complexos espícula-onda bilaterais síncronos repetitivos. Em ambas as pacientes foi utilizado o sistema de posicionamento de

eletrodos Internacional 10-20. Desta paciente, foram obtidos quatro registros, dois com 4,3 minutos (56 espículas e 13 ondas agudas; e 38 espículas e 17 ondas agudas, respectivamente), um com 6 minutos (121 espículas e 25 ondas agudas) e um com 16 minutos (238 espículas e 48 ondas agudas).

Os sinais foram adquiridos através de um encefalógrafo Grass (Model 8-16) que já possui um filtro passa-faixas (frequência de corte 20% em 1 Hz e 70 Hz). Os sinais adquiridos foram processados por um filtro passa-faixa (frequência de corte de 0,25 Hz e 175 Hz) e depois digitalizados com frequência de amostragem de 1 kHz. Após a digitalização, os dados foram processados por um filtro digital passa-faixa de segunda ordem com aproximação Butterworth (frequência de corte em 1,5 e 85 Hz) com resposta de frequência plana na faixa entre 5 e 50 Hz.


Ktonas *et al.* (1981) definiram dez descritores morfológicos baseados em amplitude, duração e inclinação (Figura 15), apresentados no Quadro 5.

Quadro 5 – Descritores propostos por Ktonas *et al.* (1981).

Símbolo	Descrição
Duração 1	Intervalo de tempo entre dois máximos ou mínimos sucessivos
Duração 2	Intervalo de tempo entre dois pontos de inflexão sucessivos
Duração A	Intervalo de tempo entre o início e o pico de uma onda
Duração B	Intervalo de tempo entre o pico e a extremidade de uma onda
Amplitude	Amplitude da linha de base até o pico de uma onda
Amplitude A	Amplitude do início da onda até seu pico
Amplitude B	Amplitude do pico até fim de uma onda
Inclinação 1	Magnitude máxima da primeira derivada durante a borda principal
Inclinação 2	Magnitude máxima da primeira derivada durante a borda seguinte
Agudeza	Valor da segunda derivada de uma onda de EEG no seu pico

Fonte: próprio autor.

Figura 15 – Descritores morfológicos apresentados por Ktonas *et al.* (1981).



Fonte: próprio autor.

3.2.5 Lemieux e Blume (1983)

Lemieux e Blume (1983) selecionaram as espículas e ondas agudas de 20 eletrocorticogramas (ECoGs). As aquisições foram realizadas usando eletrodos de bola de prata referenciados a uma referência coloidal aplicada no escalpo contralateral. Os sinais adquiridos foram condicionados através de filtros analógicos com frequência de corte superior de 70 Hz e inferior de 0,3 Hz e de um filtro *notch* centrado em 60 Hz e, na sequência, foram impressos em papel e armazenados em um gravador de fita de 14 canais.


Os dados gravados foram processados por um programa de detecção automatizada de padrões epileptiformes descrito em Vera e Blume (1978). O método consistia na digitalização dos sinais em 12 bits a 200 amostras por segundo por canal. Em seguida, os dados foram submetidos a um filtro passa baixas digital com 12 dB de atenuação a 50 Hz e diferenciados através de regressão parabólica usando o método dos mínimos quadrados com 5 pontos. O efeito combinado das operações é

um filtro passa faixas com centro em 24 Hz e 12 dB de atenuação em 7 Hz e em 36 Hz.

Vera e Blume (1978) consideraram espículas como sendo ondas compostas por uma inclinação íngreme seguida por uma outra inclinação íngreme no sentido oposto dentro de 30 a 80ms, logo, o sistema interpretava o sinal como sendo uma espícula se a derivada do sinal excedesse um valor de comparação duas vezes, com reversão no sentido dentro de 30 a 80ms.

Para a obtenção dos descritores, Lemieux e Blume (1983) antes calcularam sete pontos no padrão, nomeados de A a G, conforme indicado na Figura 16.

Figura 16 – Pontos definidos por Lemieux e Blume (1983) e os parâmetros que serão utilizados para o cálculo dos descritores morfológicos.



Fonte: Modificado de Lemieux e Blume (1983).

Os pontos A e E são os pontos de vales do sinal, que definem o início e fim do padrão, respectivamente, e o ponto C é o ponto de máxima amplitude. Desta forma, a primeira meia onda é definida como o intervalo entre os pontos A e C e a segunda, pelo intervalo entre os pontos C e E. Estes pontos foram obtidos através do método de segmentos de seqüências de Gotman e Gloor (1976).

Após a definição dos pontos de início e fim do padrão, Lemieux e Blume (1983) definiram os pontos B e D como sendo a metade da

duração de cada meia onda. Por fim, os pontos F e G marcam as máximas inclinações em cada meia onda, obtidos através do método de mínimos quadrados de 5 pontos de Vera e Blume (1978).

Após a obtenção dos sete pontos, cinco parâmetros são calculados para cada meia onda, sendo duas amplitudes (a_1 e a_2) e três durações (d_1 , d_{12} e d_{13}). De posse destes parâmetros, oito descritores para cada meia onda são calculados, subdivididos em três categorias (inclinação, duração e amplitude), conforme apresentado no Quadro 6.

Quadro 6 – Descritores morfológicos definidos por Lemieux e Blume (1983).

Inclinação	Duração	Amplitude
$SLP\ 1 = \frac{a_1}{d_1}$	$DUR\ 1 = d_1$	$AMP\ 1 = a_1$
$SLP\ 2 = \frac{a_2}{d_1/2} = \frac{a_1}{d_{12}}$	$DUR\ 2 = d_{12}$	$AMP\ 2 = 2 \cdot a_2$
$SLP\ 3 = \frac{a_1}{d_{13}}$	$DUR\ 3 = d_{13}$	

Fonte: Modificado de Lemieux e Blume (1983).

3.2.6 Pereira (2003)

O banco de dados utilizado foi apresentado por Argoud (2001), obtido com permissão do Montreal Neurological Institute (NMI) no Canadá. O banco é formado por nove registros de EEG de sete pacientes adultos; quatro destes registros possuem 60 minutos de duração, quatro registros possuem 90 minutos de duração e um registro possui 120 minutos de duração, totalizando 12 horas.

Os sinais foram amostrados a 100 Hz, em montagem bipolar do tipo zigomática-temporal (Zygo-Db-Temp), sendo que oito registros contém 32 canais e um registro contém 24 canais. Os dados foram adquiridos através de um sistema comercial (Harmonie, Stellate Systems), com filtro analógico passa-altas (frequência de corte de 0,5 Hz) e filtro limitador de banda (frequência de corte de 40 Hz).


Pereira (2003) iniciou o trabalho estudando as características de trechos de sinais com atividade de fundo normal, ondas alfa, ruídos e piscadas. A autora define a duração e a amplitude como características básicas para diferenciação dos sinais. Desta forma, a espícula é considerada como sendo um sinal com duração de 20ms a 70ms, com componente principal negativa e amplitude normalmente elevada e de grade variação. Adicionalmente, ondas agudas possuem duração entre

70ms e 200ms, com amplitudes normalmente na faixa de $20\ \mu\text{V}$ a $200\ \mu\text{V}$. Portanto, os padrões epileptiformes, em geral, apresentam características temporais na faixa de 20ms a 200ms e de amplitude na faixa de $20\ \mu\text{V}$ a $200\ \mu\text{V}$.

Os descritores (referenciados no trabalho sob a terminologia “parâmetros”) foram obtidos pela classificação em seis grupos de acordo com a grandeza envolvida: amplitude, duração, ângulo, distância, dados estatísticos e entropia.

Cada padrão foi centralizado em uma janela de um segundo (100 amostras) de sinal; na sequência, foram obtidos os valores máximo e mínimo absolutos (A_{max} e B_{min} , respectivamente), a distância entre eles (T_{dif}) e a diferença entre eles (D_{difAB}), conforme apresentado na Figura 17.

Figura 17 – Janela de 100 amostras de sinal e representação gráfica dos descritores A_{max} , B_{min} , D_{difAB} e T_{dif} .



Fonte: Pereira (2003).


O valor máximo absoluto foi utilizado como centro de uma janela de 300ms, cujas máxima e mínima amplitude ($A_{\text{max_pts}}$ e $B_{\text{min_pts}}$, respectivamente), bem como sua distância ($T_{\text{dif_pts}}$) e sua diferença ($D_{\text{difAB_pts}}$) definem outros quatro descritores (Figura 17).

A duração do padrão (T) foi obtida através da diferença entre o tempo de término e o tempo de início do padrão.

O início do padrão é considerado como sendo o primeiro ponto de cruzamento pelo eixo horizontal adjacente à A_{max} e B_{min} (dependendo de qual ocorrer primeiro), e o ponto de término é considerado como sendo o primeiro ponto de cruzamento pelo eixo horizontal após a

ocorrência de Bmin e Amax (dependendo de qual ocorrer por último), ilustrado na Figura 18.


Figura 18 – Janela de 100 amostras de sinal e representação gráfica dos descritores Amax_pts, Bmin_pts, DifAB_pts e Tdif_pts.



Fonte: Pereira (2003).

Os pontos de início e final do padrão também foram utilizados para se extrair os descritores dbase, dpos, dneg, trp, trn, θ_p , θ_n , θ , trn e trp, conforme apresentados na Figura 19.

Figura 19 – Descritores de distância temporal, inclinação e amplitude descritos por Pereira (2003).



Fonte: Modificado de Boos (2011).

O cálculo destes descritores é baseado na determinação de cinco pontos; para melhor compreensão do processo de extração dos

descritores, os pontos foram numerados de 1 a 5. Adicionalmente, como exemplo, na Figura 3, foi apresentado um padrão com ocorrência de Amax antes de Bmin, entretanto, o processamento é similar para os casos em que o padrão possua inversão na ocorrência destes extremos.

Os pontos 1 e 5 marcam os pontos de início e fim do padrão; o ponto 2 marca o ponto de maior amplitude do padrão; o ponto 4 marca a menor amplitude do padrão; e o ponto 3 marca o cruzamento pelo eixo horizontal entre os pontos 2 e 4. Dependendo da morfologia do padrão, os pontos 2 e 4 podem trocar de posição entre si.

Através dos pontos 1 e 2 é possível traçar um triângulo retângulo entre o pico máximo e o eixo horizontal. O cateto no eixo horizontal é o descritor $dpos$ (lado oposto ao ângulo do pico positivo), a hipotenusa fornece o descritor trp (distância linear entre o pico e o extremo), o ângulo junto ao pico é o descritor θp e sua tangente é o descritor $tg p$. Similarmente, através do triângulo formado pelos pontos 4, 5 e o eixo horizontal, os descritores $dneg$, trn , θn e $tg n$ podem ser obtidos.

A base do padrão ($dbase$) leva em consideração o valor absoluto dos pontos 2 e 4. Num primeiro momento, determina-se qual ponto (pico ou vale) possui maior amplitude absoluta. No caso da Figura 19, o padrão possui o vale mais pronunciado que o pico. Desta forma, a base do sinal é definida como o segmento do eixo horizontal compreendido entre o ponto 3 e o ponto 5. O descritor θ é o ângulo junto ao pico no triângulo formado pelo ponto 3, pelo eixo horizontal e pelo vértice de maior amplitude.

Todo o intervalo anterior ao ponto de início do padrão foi denominado de região inicial, analogamente, todo o intervalo após o fim do padrão é a região final. Diante disso, são obtidos os descritores referentes aos valores máximos e mínimos da região inicial ($Amax_i$ e $Bmin_i$) e da região final ($Amax_f$ e $Bmin_f$). A diferença entre as amplitudes máximas de cada uma das regiões e do pico máximo do padrão geram os descritores $DifA_i$ e $DifA_f$; e das amplitudes mínimas de cada região e do vale mínimo do padrão formam os descritores $DifB_i$ e $DifB_f$. Similarmente, a diferença temporal entre estes pontos gera os descritores $tA - i$, $tA - f$, $tB - i$ e $tB - f$.

O cálculo dos descritores estatísticos foi realizado com a janela de um segundo do sinal, através do qual se obteve o descritor de desvio padrão ($desvioC$), média ($médiaC$), coeficiente de variação ($coefC$), variância ($variC$) e o fator de crista (CFC). Os mesmos parâmetros estatísticos foram obtidos para a janela de 300ms do padrão, gerando os descritores desvio, média, coef, vari e CF.

A entropia pode ser utilizada para a obtenção do grau de irregularidade e complexidade do sinal. A entropia foi calculada através de uma função do *software* Matlab e obtida sobre o segmento de um segundo entrop_lgC (escala logarítmica) e entrop_norC (escala normalizada) e sobre a janela de 300ms entrop_lg (escala logarítmica) e entrop_nor (escala normalizada).

O Quadro 7 sumariza os descritores utilizados no trabalho de Pereira (2003).

Quadro 7 – Descritores utilizados por Pereira (2003).

Descritor	Descrição
Amax	Amplitude máxima do trecho de 1 segundo, 100 pontos
Bmin	Amplitude mínima do trecho de 1 segundo, 100 pontos
Tdif	Distância entre Amax e Bmin do trecho de 1 segundo, 100 pontos
DifAB	Diferença entre Amax e Bmin do trecho de 1 segundo, 100 pontos
Amax_pts	Amplitude máxima do trecho centrado no padrão, 30 pontos
Bmin_pts	Amplitude mínima do trecho centrado no padrão, 30 pontos
Tdif_pts	Distância entre Amax_pts e Bmin_pts do trecho centrado no padrão
DifAB_pts	Diferença entre Amax_pts e Bmax_pts do trecho centrado no padrão
T	Duração do padrão
dbase	Base do padrão, relativa a sua amplitude máxima relativa
dpos	Lado oposto ao ângulo do pico positivo
dneg	Lado oposto ao ângulo do pico negativo
trp	Distância da amplitude máxima ao extremo do padrão/amplitude máxima positiva
trn	Distância da amplitude máxima ao extremo do padrão/amplitude máxima negativa
Θ_p	Ângulo positivo
Θ_n	Ângulo negativo
Θ	Ângulo do pico, relativo ao vértice de maior amplitude do padrão
tgp	Tangente do ângulo positivo
tgn	Tangente do ângulo negativo
Amax_i	Amplitude máxima da região inicial do sinal
Bmin_i	Amplitude mínima da região inicial do sinal
DifA_i	Diferença em amplitude entre Amax e Amax_i
tA- i	Diferença em distância entre Amax e Amax_i
DifB_i	Diferença em amplitude entre Bmin e Bmin_i
tB- i	Diferença em distância entre Amin e Amin_i
Amax_f	Amplitude máxima da região final do sinal
Bmin_f	Amplitude mínima da região final do sinal

Quadro 7 – Descritores utilizados por Pereira (2003) (Continuação).

Descritor	Descrição
DifA_f	Diferença em amplitude entre Amax e Amax_f
tA- f	Diferença em distância entre Amax e Amax_f
DifB_f	Diferença em amplitude entre Bmin e Bmin_f
tB- f	Diferença em distância entre Amin e Amin_f
desvio	Desvio padrão do trecho centrado no padrão, 30 pontos
desvioC	Desvio padrão do trecho de 1 segundo, 100 pontos
média	Média do trecho centrado no padrão, 30 pontos
médiaC	Média do trecho de 1 segundo, 100 pontos
coef	Coefficiente de variação do trecho centrado no padrão, 30 pontos
coefC	Coefficiente de variação do trecho de 1 segundo, 100 pontos
vari	Variância do trecho centrado no padrão, 30 pontos
variC	Variância do trecho de 1 segundo, 100 pontos
CF	Fator de crista do trecho centrado no padrão, 30 pontos
CFC	Fator de crista do trecho de 1 segundo, 100 pontos
entrop_lgC	Entropia do trecho de 1 segundo, 100 pontos
entrop_norC	Entropia do trecho de 1 segundo, 100 pontos
entrop_log	Entropia do trecho centrado no padrão, 30 pontos
entrop_nor	Entropia do trecho centrado no padrão, 30 pontos


Fonte: próprio autor

3.2.7 Sovierzoski (2009)

Sovierzoski (2009) fez uso do mesmo banco de dados de Argoud (2001). Os registros foram analisados por um especialista, que marcou os padrões, classificando-os em espículas, ondas agudas e piscadas palpebrais. Na sequência, cada tipo de padrão foi processado para avaliar o comportamento das características estatísticas dos padrões. Este processamento foi realizado em quatro etapas: promediação, levantamento estatístico, distribuição das realizações e análise estatística.

A promediação é a representação gráfica de todos os padrões sobrepostos alinhados a um ponto de sincronismo, conforme apresentado na Figura 20(a). Baseado na promediação, o autor obteve também as envoltórias máximas e mínimas, a média e o desvio padrão, apresentados na Figura 20 (b). A Figura 20 apresenta como exemplo, a promediação de 500 espículas selecionadas aleatoriamente no banco de dados.

Figura 20 – Gráficos da (a) promediação de 500 espículas e (b) suas envoltórias superior e inferior, média e desvio padrão.




Fonte: Extraído de Sovierzoski (2009).

O levantamento estatístico foi realizado com base nos valores absolutos da primeira e da segunda meia onda (duração e amplitude), nos valores combinados das meias ondas (duração total do padrão), nos valores dos momentos estatísticos do padrão (assimetria e curtose) e nos valores obtidos através da estatística descritiva (média, desvio padrão, média mais um desvio padrão, média menos um desvio padrão, valor mínimo, valor máximo, erro padrão da média e mediana).

A distribuição das realizações foi utilizada para demonstrar graficamente o comportamento dos valores de cada característica no conjunto de padrões, conforme apresentado na Figura 21(a). A estratificação dos valores em faixas gera o histograma das realizações (Figura 21(b)), que pode auxiliar na análise das ocorrências de cada valor no conjunto de padrões. A Figura 21 apresenta um exemplo de distribuição de realizações e de histograma da característica de amplitude de 1.000 espículas do banco de dados.

Figura 21 – Distribuição da característica de amplitude de 1.000 espículas e o seu histograma correspondente.



Fonte: Extraído de Sovierzoski (2009).

A análise estatística das características dos padrões foi realizada através da ANOVA de uma via, seguida pela análise *post hoc* de Duncan para a comparação das médias dos diferentes padrões.

A análise estatística do autor demonstra que para o banco de dados utilizado, as espículas apresentam características médias de duração, duração da primeira meia-onda e duração da segunda meia onda menores que as mesmas características para os outros padrões. A média da assimetria das espículas mostrou-se maior que a média da assimetria dos outros padrões. A média da curtose para espículas e ondas agudas não apresentaram diferenças significativas, entretanto, ambos padrões apresentaram médias significativamente mais elevadas de curtose que a das piscadas palpebrais. Portanto, esta característica também pode ser utilizada para separar as piscadas dos padrões epileptiformes.

O autor apresenta uma tabela com 30 descritores, reproduzida na Quadro 8. Os quatro primeiros descritores são quatro dos descritores de Gotman (1980). Na sequência, estes descritores são combinados com as operações matemáticas básicas para a obtenção dos descritores 5 a 23, sendo que os descritores 13 e 14 são também apresentados por Lemieux e Blume (1983) e os descritores 15 e 16 são obtidos pela inversão destes. Os descritores 24 a 27 tratam-se de valores absolutos de amplitude do sinal em momentos específicos do padrão e os padrões 27 a 30 foram obtidos através de tratamento estatístico para cálculo da média, desvio padrão (calculado através da variância), assimetria e curtose.

Quadro 8 – Descritores utilizados por Sovierzoski (2009).

Nome	Descrição
a1	Amplitude da primeira meia-onda
d1	Duração da primeira meia-onda
a2	Amplitude da segunda meia-onda
d2	Duração da segunda meia-onda
a1+a2	Adição das amplitudes
d1+d2	Duração do padrão
a1*a2	Produto das amplitudes
d1*d2	Produto das durações das meias ondas
a1/a2	Razão das amplitudes a1 e a2
a2/a1	Razão das amplitudes a2 e a1
d1/d2	Razão entre a duração da primeira e da segunda meia-onda
d2/d1	Razão entre a duração da segunda e da primeira meia-onda
a1/d1	Razão entre a amplitude e a duração da primeira meia-onda
a2/d2	Razão entre a amplitude e a duração da segunda meia-onda
d1/a1	Razão entre a duração e a amplitude da primeira meia-onda
d2/a2	Razão entre a duração e a amplitude da segunda meia-onda
d1/(d1+d2)	Proporção da duração da primeira meia-onda em relação a duração do padrão
d2/(d1+d2)	Proporção da duração da segunda meia-onda em relação à duração do padrão
d1*a1/2	Estimativa da área da primeira meia-onda
d2*a2/2	Estimativa da área da segunda meia-onda
(a1+a2)/2	Média das amplitudes do padrão
hipot1	Comprimento linear da primeira meia-onda
hipot2	Comprimento linear da segunda meia-onda
A1	Valor absoluto da amplitude no início da primeira meia-onda
A2	Valor absoluto da amplitude no valor pico do padrão, término da primeira meia-onda
A3	Valor absoluto da amplitude no término da segunda meia-onda
HOS_media	<i>High Order Statistics</i> – média das amostras do padrão
HOS_desvpadr	<i>High Order Statistics</i> – desvio padrão das amostras do padrão
HOS_assimetria	<i>High Order Statistics</i> – assimetria das amostras do padrão
HOS_curtose	<i>High Order Statistics</i> – curtose das amostras do padrão

3.3 ALGORITMO PARA EXTRAÇÃO DOS DESCRITORES

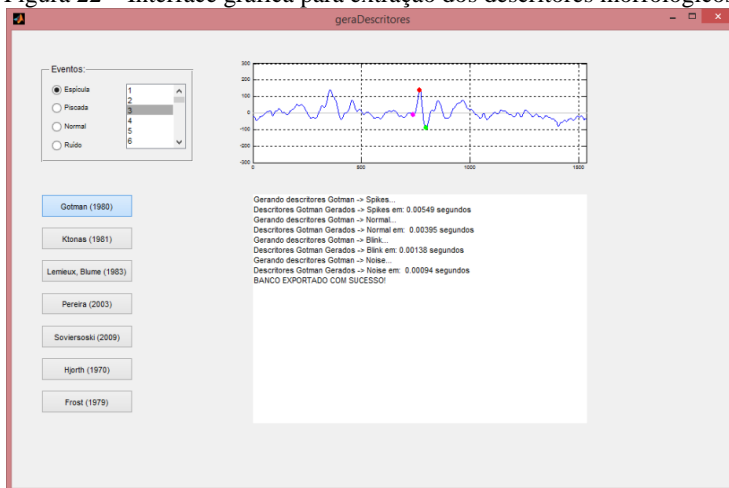
Foi desenvolvido um algoritmo no *software* MatLab[®] para a extração dos descritores do banco de dados. Num primeiro momento, o

algoritmo realiza um processo de filtragem adicional conforme descrição do trabalho de cada autor. Na sequência os pontos de início e término do padrão eram obtidos conforme o método descrito pelo autor, bem como os pontos intermediários quando necessários. Os parâmetros relacionados à distância, à amplitude e à inclinação entre os pontos eram calculados para auxiliar na extração dos descritores. Por fim, os descritores eram calculados baseados nos parâmetros e cada conjunto de descritores era exportado para um arquivo em formato próprio do MatLab[®] para posterior utilização como entrada do classificador neural.

A Figura 22 apresenta uma visão da interface gráfica desenvolvida. Com os botões representando cada autor (conjunto de descritor), uma tela de informação ao usuário sobre a exportação dos descritores, um painel de controle dos arquivos do banco de dados com todos os seguimentos possibilitando maior controle dos descritores extraídos, basta selecionar qual o tipo de padrão, padrão epileptiforme, ruído, normal ou piscada e escolher o número do arquivo desejado.

Além de realizar a extração dos descritores o algoritmo já realiza a separação do banco de dados em treinamento, validação e teste para ser posteriormente ser utilizado como entrada do classificador neural.

Figura 22 – Interface gráfica para extração dos descritores morfológicos.



Fonte: próprio autor.

3.4 REDE NEURAL ARTIFICIAL

O classificador utilizado neste trabalho é uma rede neural artificial em configuração Perceptron Multicamadas.

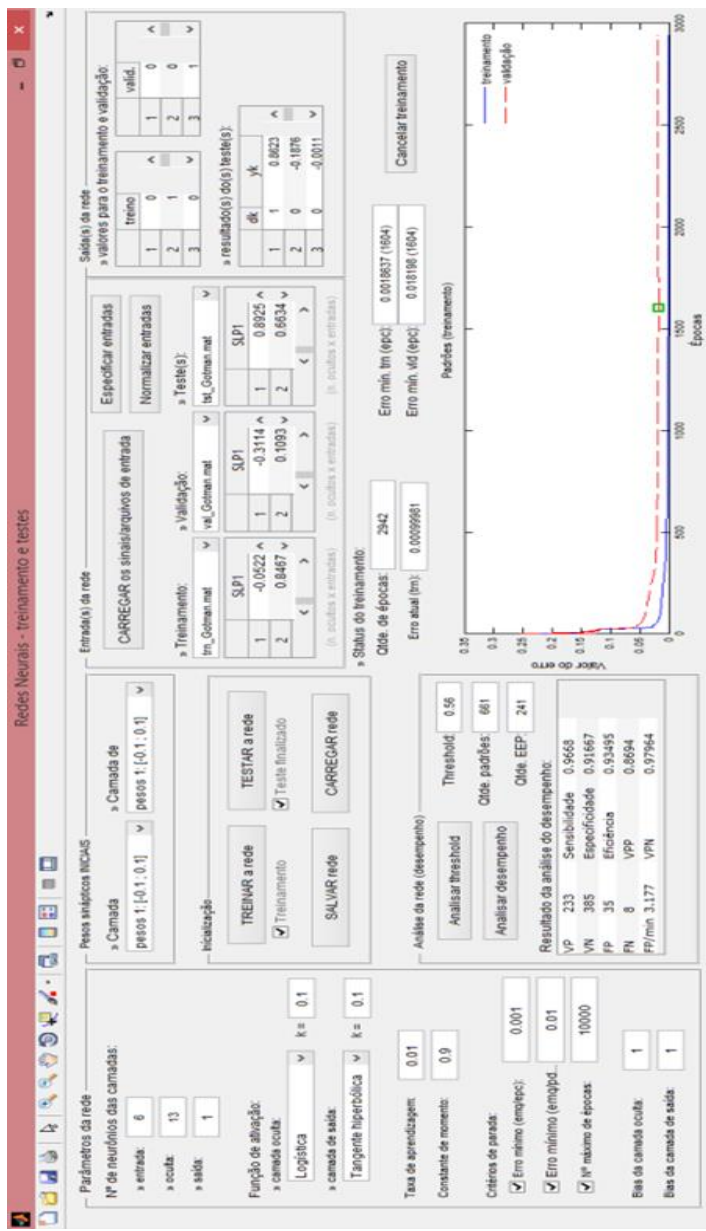
A rede é composta de três camadas (entrada, oculta e saída), sendo que a camada de entrada possuía o número de neurônios igual ao número de descritores do autor a ser estudado e um *bias*; para a camada intermediária, pode-se configurar o número de neurônios entre 1 e 200 e um *bias*, e uma camada de saída com um neurônio.

A interface gráfica da rede neural permite a escolha de uma função de ativação e inclinação distintas para cada conjunto de pesos (entrada-intermediária e intermediária-saída), como pode ser observado na Figura 23. Nesta figura ainda pode ser observado o gráfico de um dos treinamentos do conjunto de descritores de Gotman (1980), o erro mínimo de treinamento e os índices de desempenho após a execução do teste da rede treinada.

O treinamento da rede neural é supervisionado, possuindo um conjunto de treinamento e um de validação, com atualizações dos pesos através do algoritmo de retropropagação do erro (*Error Backpropagation*) ao final de cada época de treinamento. Os erros de treinamento e de validação são calculados e os pesos das camadas são armazenados sempre que um erro de validação mais baixo é atingido. Desta forma, o melhor desempenho de cada treinamento fica disponível para análise futura.

Após o treinamento, os padrões do conjunto de teste são propagados e uma análise de limiar de decisão é realizada para determinação dos totais de VP, VN, FP, e FN. De posse destes dados, é calculada a sensibilidade e a especificidade para cada limiar de decisão para aquele conjunto de pesos.

Figura 23 – Interface gráfica utilizada nas simulações e testes para implementação das redes neurais.



Fonte: próprio autor.

3.5 MÉTRICAS DE ANÁLISE DO DESEMPENHO

A análise de desempenho dos classificadores pode ser realizada por meio de métricas, visto que diferentes campos do conhecimento aplicam uma ou outra métrica para analisar seus testes, devido, principalmente, a seus objetivos diferentes. Avaliação do desempenho é uma etapa importante do processamento de sinais biomédicos.

Na área médica, normalmente as métricas preferidas são aquelas baseadas em sensibilidade e especificidade (MAZUROWSKI *et al.*, 2008). Porém, efetuar uma comparação de desempenho entre dois classificadores através de duas métricas duais, em uma condição não conhecida de avaliação, pode não ser conclusivo. Dessa forma, é necessário recorrer a outras métricas de desempenho, como as singulares, que expressem conjuntamente as características da sensibilidade e da especificidade para determinar qual é o classificador com melhor desempenho.

Um dos índices de desempenho singular é o EER (Taxa de Erro Igual) que pode ser utilizado para auxílio na determinação do melhor classificador. Ele é obtido como resultado do cruzamento dos gráficos da sensibilidade e da especificidade, determinando o ponto de taxa de erro igual.

A AC (Correlação Aproximada) é outro índice de desempenho que pode ajudar na determinação do melhor do classificador, uma vez que seja utilizado em conjunto com os demais índices citados anteriormente. A vantagem deste índice, em relação aos índices de sensibilidade e especificidade, é que o desempenho do classificador é representado por um único valor.

Adicionalmente aos índices singulares EER e AC, este trabalho propôs ainda uma avaliação de desempenho de classificadores utilizando a Eficiência e o índice de Youden, pois ambos tem por característica também ser representado por um único valor. Apesar da literatura indicar o uso de um ou de outro este trabalho optou por fazer uso de ambos os indicadores, devido a familiaridade que cada pesquisador possui em relação aos índices de desempenho.

4 RESULTADOS E DISCUSSÃO

Este capítulo apresenta 224 dos treinamentos de redes neurais utilizando os conjuntos de descritores extraídos. Os treinamentos foram separados em 32 topologias distintas para cada um dos conjuntos de descritores morfológicos. Nas seções seguintes, o resultado de cada conjunto de descritores morfológicos é apresentado.

Nos 32 treinamentos, foram priorizadas as alterações na configuração da camada intermediária e das funções de ativação e suas inclinações.

4.1 CONJUNTO DE HJORTH (1970)

O conjunto de descritores de Hjorth (1970) utiliza apenas três descritores morfológicos, portanto os treinamentos foram realizados com o tamanho da camada intermediária sendo variando entre 2 e 12 neurônios (SILVA; SPATTI; FLAUZINO, 2010). Foi testada a utilização de funções de ativação logística e tangente hiperbólica, com inclinações de 0,1 a 0,9. Os resultados obtidos são apresentados na **Erro! Fonte de referência não encontrada..** As células da tabela com preenchimento em cinza indicam as redes que obtiveram o máximo valor para o índice de desempenho avaliado. São apresentados quatro índices de desempenho singulares e o limiar no qual eles ocorrem (Thre): taxa de erro igual (EER), eficiência (ACC), coeficiente de correlação aproximada (AC) desenvolvido por Burset e Guigó (1996) e índice de Youden (J).

As redes não apresentaram valores de eficiência inferiores a 0,6. Embora o treinamento da rede seja rápido, devido a pequena quantidade de neurônios das camadas de entrada e intermediária, todos os índices estatísticos obtidos foram inferiores aos obtidos pelos demais conjuntos apresentados nas seções seguintes neste trabalho.

Nenhuma rede apresentou índice AC e índice J superiores a 0,71. Mesmo o maior índice EER obtido (treinamento 3:5:1, log 0,1, log 0,1) foi considerado baixo, apresentando discriminação inferior a 72%.

Este resultado sugere que a utilização do conjunto de descritores de Hjorth (1970), não é promissora para a classificação de padrões epileptiformes.

Tabela 4 – Desempenho das RNAs utilizando o conjunto de Hjorth.

Neurônios	Ativação	EER	Thre	ACC	Thre	accSen	accEsp	accPpv	accPpn	AC	Thre	J	Thre
03:02:01	log0,1/log0,1	0,67	0,66	0,70	0,77	0,531	0,790	0,592	0,746	0,632	0,40	0,64	0,43
03:03:01	log0,1/log0,1	0,69	0,89	0,71	0,93	0,544	0,800	0,609	0,753	0,666	0,70	0,67	0,70
03:04:01	log0,1/log0,1	0,70	0,86	0,70	0,83	0,747	0,669	0,564	0,822	0,658	0,53	0,67	0,64
03:05:01	log0,1/log0,1	0,71	0,87	0,72	0,96	0,523	0,831	0,639	0,752	0,697	0,72	0,70	0,72
03:06:01	log0,1/log0,1	0,69	0,88	0,69	0,84	0,747	0,664	0,560	0,821	0,664	0,58	0,66	0,58
03:07:01	log0,1/log0,1	0,69	0,87	0,70	0,97	0,423	0,859	0,633	0,722	0,658	0,54	0,66	0,6
03:08:01	log0,1/log0,1	0,70	0,87	0,70	0,87	0,697	0,697	0,569	0,801	0,66	0,53	0,66	0,53
03:09:01	log0,1/log0,1	0,70	0,88	0,70	0,89	0,685	0,709	0,574	0,797	0,657	0,52	0,68	0,74
03:10:01	log0,1/log0,1	0,68	0,90	0,69	0,96	0,564	0,757	0,571	0,752	0,655	0,54	0,67	0,62
03:11:01	log0,1/log0,1	0,68	0,89	0,69	0,96	0,568	0,754	0,570	0,753	0,66	0,57	0,66	0,59
03:12:01	log0,1/log0,1	0,68	0,89	0,68	0,86	0,710	0,666	0,549	0,800	0,644	0,45	0,65	0,52
03:07:01	tg0,3/tg0,3	0,69	0,52	0,71	0,59	0,589	0,781	0,606	0,768	0,675	0,43	0,67	0,43
03:07:01	tg0,7/tg0,7	0,70	0,05	0,72	0,08	0,573	0,807	0,630	0,767	0,664	0,01	0,69	0,03
03:07:01	tg0,9/tg0,9	0,61	0,42	0,68	0,42	0,353	0,864	0,598	0,699	0,523	0,41	0,52	0,41
03:07:01	log0,1/tg0,1	0,70	0,52	0,71	0,52	0,647	0,742	0,590	0,786	0,708	0,52	0,71	0,52
03:07:01	log0,3/tg0,3	0,66	0,40	0,70	0,54	0,515	0,802	0,599	0,742	0,635	0,22	0,64	0,23

Legenda: **EER** – Equal Error Rate, **Thre** – Threshold, **accSen** – Valor da Sensibilidade para a Maior Eficiência, **accEsp** – Valor da Especificidade para a Maior Eficiência, **accPpv** – Valor Preditivo Positivo para a Maior Eficiência, **accPpn** – Valor Preditivo Negativo para a Maior Eficiência, **AC** – Coeficiente de Correlação Aproximada, **J** – Índice de Youden.

Tabela 4 – Desempenho das RNAs utilizando o conjunto de Hjorth.(Continuação)

Neurônios	Ativação	EER	Thre	ACC	Thre	accSen	accEsp	accPpv	accPpn	AC	Thre	J	Thre
03:07:01	log0,9/tg0,9	0,49	0,66	0,64	0,67	0,000	1,000	0,000	0,635	0,369	0,66	0,36	0,00
03:07:01	tg0,1/log0,1	0,69	0,45	0,72	0,70	0,498	0,840	0,641	0,745	0,651	0,18	0,67	0,23
03:07:01	tg0,3/log0,3	0,69	0,34	0,72	0,58	0,539	0,828	0,643	0,758	0,641	0,1	0,67	0,16
03:07:01	tg0,5/log0,5	0,67	0,33	0,68	0,62	0,485	0,790	0,570	0,728	0,646	0,08	0,65	0,09
03:07:01	tg0,7/log0,7	0,68	0,57	0,71	0,89	0,473	0,800	0,644	0,738	0,617	0,06	0,65	0,18
03:07:01	tg0,9/log0,9	0,67	0,24	0,72	0,53	0,515	0,838	0,645	0,751	0,637	0,05	0,67	0,10
03:07:01	log0,1/log0,1	0,69	0,87	0,70	0,97	0,423	0,859	0,633	0,722	0,658	0,54	0,66	0,60
03:07:01	log0,2/log0,2	0,69	0,88	0,69	0,88	0,693	0,688	0,560	0,796	0,655	0,5	0,66	0,55
03:07:01	log0,3/log0,3	0,69	0,88	0,69	0,9	0,676	0,704	0,567	0,791	0,655	0,5	0,66	0,56
03:07:01	log0,4/log0,4	0,70	0,88	0,70	0,88	0,693	0,697	0,568	0,798	0,666	0,58	0,67	0,58
03:07:01	log0,5/log0,5	0,70	0,87	0,70	0,89	0,676	0,714	0,576	0,794	0,657	0,51	0,67	0,57
03:07:01	log0,6/log0,6	0,68	0,89	0,68	0,88	0,689	0,676	0,549	0,791	0,661	0,53	0,67	0,59
03:07:01	log0,7/log0,7	0,67	0,89	0,68	0,86	0,730	0,647	0,543	0,807	0,664	0,56	0,67	0,58
03:07:01	log0,8/log0,8	0,67	0,89	0,67	0,85	0,743	0,635	0,539	0,812	0,664	0,56	0,67	0,58
03:07:01	log0,9/log0,9	0,68	0,89	0,68	0,89	0,689	0,678	0,551	0,792	0,664	0,57	0,67	0,61

Legenda: **EER** – Equal Error Rate, **Thre** – Threshold, **accSen** – Valor da Sensibilidade para a Maior Eficiência, **accEsp** – Valor da Especificidade para a Maior Eficiência, **accPpv** – Valor Preditivo Positivo para a Maior Eficiência, **accPpn** – Valor Preditivo Negativo para a Maior Eficiência, **AC** – Coeficiente de Correlação Aproximada, **J** – Índice de Youden.

4.2 CONJUNTO DE FROST (1979)

O conjunto de Frost (1979) é composto por seis descritores morfológicos. Os treinamentos foram realizados com o tamanho da camada intermediária sendo variada entre 8 e 18 neurônios, analisando funções de ativação logística e tangente hiperbólica, com inclinações de 0,1 a 0,9. Os resultados obtidos são apresentados na Tabela 5.

As células da tabela com preenchimento em cinza apresentam as situações em que a rede obteve o máximo valor para o índice de desempenho avaliado. São apresentados quatro índices de desempenho singulares e o limiar no qual eles ocorrem (Thre): taxa de erro igual (EER), eficiência (ACC), coeficiente de correlação aproximada (AC) desenvolvido por Burset e Guigó (1996) e índice de Youden (J).

Em quatro casos as redes neurais apresentaram eficiência com valores inferiores a 0,7. O maior valor de eficiência foi obtido no treinamento 6:13:1, log 0,9, tg 0,9 no *threshold* 0,62. Este mesmo treinamento também apresentou o maior AC, também no *threshold* 0,62 e o maior J.

O maior EER foi obtido no treinamento 6:13:1, tg 0,7/log 0,7, com *threshold* 0,66. Embora o índice EER não tenha sido máximo no treinamento 6:13:1, log 0,9, tg 0,9 no *threshold* 0,63, o treinamento apresentou valor bem próximo do máximo.

Este resultado sugere que o treinamento 6:13:1, log 0,9, tg 0,9 no *threshold* 0,62, pode ser considerado como o melhor dentre os treinamentos do conjunto Frost (1979), uma vez que seu resultado é máximo para três dos quatro índices estatísticos (ACC, AC e J) e elevado para um deles (EER).

Tabela 5 – Desempenho das RNAs utilizando o conjunto de Frost.

Neurônios	Ativação	EER	Thre	ACC	Thre	accSen	accEsp	accPpv	accPpn	AC	Thre	J	Thre
06:08:01	log0,1/log0,1	0,8913	0,90	0,894	0,91	0,892	0,8952	0,830	0,935	0,894	0,91	0,888	0,83
06:09:01	log0,1/log0,1	0,8949	0,95	0,903	0,98	0,838	0,9405	0,890	0,910	0,900	0,92	0,899	0,90
06:10:01	log0,1/log0,1	0,8946	0,90	0,902	0,86	0,929	0,8857	0,824	0,956	0,901	0,86	0,902	0,86
06:11:01	log0,1/log0,1	0,8961	0,93	0,899	0,94	0,879	0,9095	0,848	0,929	0,898	0,94	0,888	0,81
06:12:01	log0,1/log0,1	0,8958	0,91	0,899	0,87	0,925	0,8833	0,820	0,954	0,898	0,87	0,899	0,87
06:13:01	log0,1/log0,1	0,899	0,92	0,899	0,87	0,933	0,8786	0,815	0,958	0,898	0,87	0,899	0,87
06:14:01	log0,1/log0,1	0,8946	0,91	0,899	0,93	0,892	0,9024	0,840	0,936	0,897	0,87	0,896	0,86
06:15:01	log0,1/log0,1	0,8978	0,92	0,900	0,91	0,908	0,8952	0,833	0,945	0,900	0,91	0,897	0,87
06:16:01	log0,1/log0,1	0,9047	0,93	0,905	0,93	0,904	0,9048	0,845	0,943	0,904	0,93	0,902	0,91
06:17:01	log0,1/log0,1	0,9035	0,94	0,905	0,93	0,908	0,9024	0,842	0,945	0,904	0,93	0,905	0,93
06:18:01	log0,1/log0,1	0,9047	0,94	0,906	0,96	0,888	0,9167	0,859	0,934	0,904	0,91	0,905	0,91
06:13:01	tg0,1/tg0,1	0,7364	0,32	0,752	0,51	0,622	0,8262	0,673	0,792	0,748	0,41	0,720	0,32
06:13:01	tg0,3/tg0,3	0,7238	0,20	0,747	0,23	0,643	0,8071	0,657	0,798	0,747	0,23	0,737	0,21
06:13:01	tg0,7/tg0,7	0,4749	1,00	0,555	1,00	0,178	0,7714	0,309	0,621	0,473	0,46	0,501	0,51
06:13:01	tg0,9/tg0,9	0,5736	0,99	0,634	1,00	0,008	0,9929	0,400	0,636	0,470	0,99	0,470	0,99
06:13:01	log0,1/tg0,1	0,7125	0,31	0,725	0,53	0,639	0,7738	0,618	0,789	0,652	0,27	0,711	0,31
06:13:01	log0,3/tg0,3	0,500	0,00	0,635	0,65	0,000	1,000	0,000	0,635	0,364	0,12	0,365	0,20

Legenda: **EER** – Equal Error Rate, **Thre** – Threshold, **accSen** – Valor da Sensibilidade para a Maior Eficiência, **accEsp** – Valor da Especificidade para a Maior Eficiência, **accPpv** – Valor Preditivo Positivo para a Maior Eficiência, **accPpn** – Valor Preditivo Negativo para a Maior Eficiência, **AC** – Coeficiente de Correlação Aproximada, **J** – Índice de Youden.

Tabela 5 – Desempenho das RNAs utilizando o conjunto de Frost (Continuação)..

Neurônios	Ativação	EER	Thre	ACC	Thre	accSen	accEsp	accPpv	accPpn	AC	Thre	J	Thre
06:13:01	log0,5/tg0,5	0,449	0,85	0,635	0,94	0,000	1,000	0,000	0,635	0,409	0,80	0,461	0,82
06:13:01	log0,9/tg0,9	0,9038	0,63	0,911	0,62	0,917	0,907	0,850	0,950	0,910	0,62	0,911	0,62
06:13:01	tg0,1/tg0,1	0,9035	0,74	0,908	0,63	0,946	0,885	0,826	0,966	0,907	0,63	0,908	0,63
06:13:01	tg0,3/tg0,3	0,9059	0,73	0,909	0,76	0,900	0,914	0,858	0,941	0,906	0,68	0,906	0,68
06:13:01	tg0,5/tg0,5	0,9047	0,69	0,909	0,78	0,871	0,931	0,879	0,927	0,903	0,49	0,903	0,49
06:13:01	tg0,7/tg0,7	0,9091	0,66	0,909	0,66	0,908	0,909	0,852	0,946	0,907	0,59	0,900	0,47
06:13:01	tg0,9/tg0,9	0,8990	0,92	0,899	0,87	0,933	0,878	0,815	0,958	0,898	0,87	0,899	0,87
06:13:01	log0,2/tg0,2	0,8966	0,93	0,906	0,87	0,950	0,881	0,821	0,969	0,906	0,87	0,906	0,87
06:13:01	log0,3/tg0,3	0,899	0,92	0,900	0,94	0,883	0,909	0,849	0,932	0,898	0,90	0,899	0,90
06:13:01	log0,4/tg0,4	0,8969	0,92	0,902	0,95	0,875	0,916	0,858	0,928	0,898	0,89	0,899	0,89
06:13:01	log0,5/tg0,5	0,8969	0,92	0,902	0,95	0,875	0,916	0,858	0,928	0,898	0,9	0,899	0,90
06:13:01	log0,6/tg0,6	0,8958	0,92	0,902	0,95	0,875	0,916	0,858	0,928	0,901	0,95	0,897	0,90
06:13:01	log0,7/tg0,7	0,8969	0,93	0,902	0,95	0,875	0,916	0,858	0,928	0,898	0,90	0,899	0,90
06:13:01	log0,8/tg0,8	0,8946	0,92	0,902	0,95	0,875	0,916	0,858	0,928	0,901	0,95	0,897	0,89
06:13:01	log0,9/tg0,9	0,8969	0,93	0,902	0,88	0,933	0,883	0,821	0,959	0,901	0,88	0,902	0,88

Legenda: **EER** – Equal Error Rate, **Thre** – Threshold, **accSen** – Valor da Sensibilidade para a Maior Eficiência, **accEsp** – Valor da Especificidade para a Maior Eficiência, **accPpv** – Valor Preditivo Positivo para a Maior Eficiência, **accPpn** – Valor Preditivo Negativo para a Maior Eficiência, **AC** – Coeficiente de Correlação Aproximada, **J** – Índice de Youden.

4.3 CONJUNTO DE GOTMAN (1980)

Gotman (1980) apresentou um conjunto com seis descritores morfológicos. Os treinamentos foram realizados com o tamanho da camada intermediária variando entre 8 e 18 neurônios, com as funções de ativação logística e tangente hiperbólica, com inclinações de 0,1 a 0,9. Os resultados obtido são apresentados na Tabela 6.

As células da tabela são marcadas **negrito** apresenta resultados considerados insatisfatórios, pois indicam situações em que a rede neural não é capaz de distinguir padrões epileptiformes de padrões não-epileptiformes.

As células da tabela são marcadas com preenchimento em cinza apresentam as situações em que a rede obteve o máximo valor para o índice de desempenho avaliado. São apresentados quatro índices de desempenho singulares e o limiar no qual eles ocorrem (Thre): taxa de erro igual (EER), eficiência (ACC), coeficiente de correlação aproximada (AC) desenvolvido por Burset e Guigó (1996) e índice de Youden (J).

Em nenhum dos testes, as redes apresentaram eficiência inferiores a 0,6. O maior valor de eficiência foi de 0,934947, obtido com o treinamento 6:8:1, log 0,1, log 0,1 no *threshold* 0,91. Este mesmo treinamento apresentou o maior valor de EER com 0,931 e também o maior valor de J, com *threshold* 0,87.

Este resultado sugere que o treinamento 6:8:1 ou 6:9:1 log 0,1, log 0,1, pode ser considerado como o melhor dentre os treinamentos do conjunto Gotman (1980), uma vez que seu resultado é máximo para três dos quatro índices estatísticos (ACC, J e EER).

Tabela 6 – Desempenho das RNAs utilizando o conjunto de Gotman.

Neurônios	Ativação	EER	Thre	ACC	Thre	accSen	accEsp	accPpv	accPpn	AC	Thre	J	Thre
06:08:01	log 0.1 / log 0.1	0.931	0.89	0.934947	0.91	0.912863	0.94762	0.9090	0.94988	0.93343	0.87	0.93343	0.87
06:09:01	log 0.1 / log 0.1	0.931	0.89	0.934947	0.91	0.912863	0.94762	0.9090	0.94988	0.93343	0.87	0.93343	0.87
06:10:01	log 0.1 / log 0.1	0.931	0.89	0.933434	0.87	0.950207	0.92381	0.8774	0.97000	0.93343	0.87	0.93343	0.87
06:11:01	log 0.1 / log 0.1	0.931	0.89	0.933434	0.87	0.950207	0.92381	0.8774	0.97000	0.93343	0.87	0.93343	0.87
06:12:01	log 0.1 / log 0.1	0.929	0.88	0.931921	0.90	0.917012	0.94048	0.8983	0.95181	0.93192	0.90	0.92133	0.8
06:13:01	log 0.1 / log 0.1	0.929	0.88	0.931921	0.90	0.917012	0.94048	0.8983	0.95181	0.93192	0.90	0.92133	0.8
06:14:01	log 0.1 / log 0.1	0.929	0.88	0.933434	0.90	0.917012	0.94286	0.9020	0.95192	0.93343	0.90	0.92436	0.84
06:15:01	log 0.1 / log 0.1	0.929	0.88	0.933434	0.90	0.917012	0.94286	0.9020	0.95192	0.93343	0.90	0.92436	0.84
06:16:01	log 0.1 / log 0.1	0.929	0.88	0.933434	0.90	0.917012	0.94286	0.9020	0.95192	0.93343	0.90	0.92436	0.84
06:17:01	log 0.1 / log 0.1	0.929	0.88	0.933434	0.90	0.917012	0.94286	0.9020	0.95192	0.93343	0.90	0.92436	0.84
06:18:01	log 0.1 / log 0.1	0.881	0.57	0.886536	0.56	0.900415	0.87857	0.8097	0.93893	0.88654	0.56	0.88654	0.56
06:13:01	tg 0.1 / tg 0.1	0.881	0.57	0.886536	0.56	0.900415	0.87857	0.8097	0.93893	0.88654	0.56	0.88654	0.56
06:13:01	tg 0.3 / tg 0.3	0.699	0.42	0.701967	0.43	0.394191	0.87857	0.6506	0.71651	0.63843	0.42	0.63843	0.42
06:13:01	tg 0.7 / tg 0.7	0.880	0.82	0.880484	0.79	0.929461	0.85238	0.7832	0.95467	0.88048	0.79	0.88048	0.79
06:13:01	tg 0.9 / tg 0.9	0.433	0.05	0.635401	0.07	0.143522	0.34988	0.16374	0.63540	0.63389	0.06	0.3646	0.30
06:13:01	log 0.1 / tg 0.1	0.931	0.61	0.934947	0.56	0.966805	0.91667	0.8694	0.97964	0.93495	0.56	0.93192	0.52
06:13:01	log 0.3 / tg 0.3	0.5000	0.20	0.6354	0.65	0.0000	1.0000	0.0000	0.6354	0.36460	0.44	0.3646	0.54

Legenda: **EER** – Equal Error Rate, **Thre** – Threshold, **accSen** – Valor da Sensibilidade para a Maior Eficiência, **accEsp** – Valor da Especificidade para a Maior Eficiência, **accPpv** – Valor Preditivo Positivo para a Maior Eficiência, **accPpn** – Valor Preditivo Negativo para a Maior Eficiência, **AC** – Coeficiente de Correlação Aproximada, **J** – Índice de Youden.

Tabela 6 – Desempenho das RNAs utilizando o conjunto de Gotman (Continuação).

Neurônios	Ativação	EER	Thre	ACC	Thre	accSen	accEsp	accPpv	accPpn	AC	Thre	J	Thre
06:13:01	log 0.5 / tg 0.5	0.5000	0.43	0.6354	0.96	0.0000	1.0000	0.0000	0.6354	0.36460	0.21	0.3646	0.60
06:13:01	log 0.9 / tg 0.9	0.9281	0.62	0.9288	0.61	0.9336	0.92619	0.8789	0.96049	0.92890	0.61	0.92284	0.56
06:13:01	tg 0.1 / log 0.1	0.9281	0.43	0.9288	0.43	0.9253	0.95095	0.8849	0.95599	0.92890	0.43	0.92284	0.38
06:13:01	tg 0.3 / log 0.3	0.9224	0.28	0.9243	0.27	0.9336	0.91905	0.8687	0.9602	0.92284	0.24	0.92284	0.24
06:13:01	tg 0.5 / log 0.5	0.9266	0.28	0.9273	0.29	0.9211	0.95095	0.8844	0.95366	0.92738	0.29	0.92133	0.22
06:13:01	tg 0.7 / log 0.7	0.9266	0.28	0.9273	0.29	0.9211	0.95095	0.8844	0.95366	0.92738	0.29	0.91831	0.20
06:13:01	tg 0.9 / log 0.9	0.9299	0.88	0.9319	0.90	0.9170	0.94048	0.8983	0.95181	0.93192	0.90	0.92133	0.80
06:13:01	log 0.2 / log 0.2	0.9299	0.88	0.9334	0.90	0.9170	0.94286	0.9020	0.95192	0.93192	0.87	0.92133	0.80
06:13:01	log 0.3 / log 0.3	0.9141	0.96	0.9183	0.97	0.8796	0.94048	0.8945	0.9316	0.91831	0.97	0.90923	0.91
06:13:01	log 0.4 / log 0.4	0.9162	0.96	0.9183	0.96	0.9087	0.92381	0.8725	0.94634	0.91831	0.96	0.91074	0.92
06:13:01	log 0.5 / log 0.5	0.9183	0.96	0.9198	0.96	0.9128	0.92381	0.8730	0.94866	0.91982	0.96	0.91074	0.92
06:13:01	log 0.6 / log 0.6	0.9183	0.96	0.9198	0.96	0.9128	0.92381	0.8730	0.94866	0.91982	0.96	0.91074	0.92
06:13:01	log 0.7 / log 0.7	0.9183	0.96	0.9198	0.96	0.9128	0.92381	0.8730	0.94866	0.91982	0.96	0.90923	0.91
06:13:01	log 0.8 / log 0.8	0.9183	0.96	0.9198	0.96	0.9128	0.92381	0.8730	0.94866	0.91982	0.96	0.90923	0.91
06:13:01	log 0.9 / log 0.9	0.9183	0.96	0.9198	0.96	0.9128	0.92381	0.8730	0.94866	0.91982	0.96	0.90469	0.86

Legenda: **EER** – Equal Error Rate, **Thre** – Threshold, **accSen** – Valor da Sensibilidade para a Maior Eficiência, **accEsp** – Valor da Especificidade para a Maior Eficiência, **accPpv** – Valor Preditivo Positivo para a Maior Eficiência, **accPpn** – Valor Preditivo Negativo para a Maior Eficiência, **AC** – Coeficiente de Correlação Aproximada, **J** – Índice de Youden.

4.4 CONJUNTO DE KTONAS ET AL. (1981)

Ktonas *et al.* (1981) propuseram um conjunto com dez descritores morfológicos. Seguindo a lógica anterior, os treinamentos foram realizados com o tamanho da camada intermediária sendo variado entre 16 e 26 neurônios, com as funções de ativação logística e tangente hiperbólica, com inclinações de 0,1 a 0,9. Os resultados obtidos são apresentados na Tabela 7.

As células da tabela com preenchimento em cinza apresentam as situações em que a rede obteve o máximo valor para o índice de desempenho avaliado. São apresentados quatro índices de desempenho singulares e o limiar no qual eles ocorrem (Thre): taxa de erro igual (EER), eficiência (ACC), coeficiente de correlação aproximada (AC) desenvolvido por Burset e Guigó (1996) e índice de Youden (J).

Novamente, as redes não apresentaram eficiência inferiores a 0,6. O maior valor de eficiência foi de 0,95, obtido no treinamento 10:21:1, tg 0,5 / log 0,5 com *threshold* 0,94. Nestes mesmos treinamento e *threshold* também foi obtido o maior AC de 0,95.

O maior EER e J foram obtidos com o treinamento 10:21:01 log 0,7 / log 0,7 com *threshold* 0,99.

Este resultado sugere que o treinamento 10:21:1, tg 0,5 / log 0,5 pode ser considerado como o melhor dentre os treinamentos do conjunto de Ktonas *et al.* (1981), uma vez que seu resultado é máximo para dois dos quatro índices estatísticos (ACC e AC) e quase máximo para os outros dois índices (EER e J).

Tabela 7 – Desempenho das RNAs utilizando o conjunto de Ktonas *et al.*

Neurônios	Ativação	EER	Thre	ACC	Thre	accSen	accEsp	accPpv	accPpn	AC	Thre	J	Thre
10:16:01	log 0.1 / log 0.1	0.9367	0.98	0.9379	0.97	0.9668	0.9214	0.8759	0.9797	0.9379	0.97	0.93790	0.97
10:17:01	log 0.1 / log 0.1	0.9367	0.98	0.9379	0.97	0.9668	0.9214	0.8759	0.9797	0.9379	0.97	0.93494	0.96
10:18:01	log 0.1 / log 0.1	0.9403	0.99	0.9410	0.99	0.9377	0.9428	0.9040	0.9635	0.9379	0.98	0.93797	0.98
10:19:01	log 0.1 / log 0.1	0.9423	0.99	0.9425	0.99	0.9419	0.9428	0.9043	0.9658	0.9425	0.99	0.93646	0.98
10:20:01	log 0.1 / log 0.1	0.9423	0.99	0.9425	0.99	0.9419	0.9428	0.9043	0.9658	0.9425	0.99	0.93646	0.98
10:21:01	log 0.1 / log 0.1	0.9423	0.99	0.9425	0.99	0.9419	0.9428	0.9043	0.9658	0.9425	0.99	0.93646	0.98
10:22:01	log 0.1 / log 0.1	0.9403	0.99	0.9410	0.99	0.9377	0.9428	0.9040	0.9635	0.9394	0.98	0.93948	0.98
10:23:01	log 0.1 / log 0.1	0.9459	0.99	0.9470	0.99	0.9419	0.9500	0.9153	0.9661	0.9470	0.99	0.94705	0.99
10:24:01	log 0.1 / log 0.1	0.9418	0.99	0.9440	0.99	0.9336	0.9500	0.9146	0.9614	0.9425	0.98	0.94251	0.98
10:25:01	log 0.1 / log 0.1	0.9480	0.99	0.9485	0.99	0.9460	0.9500	0.9156	0.9684	0.9485	0.99	0.94856	0.99
10:26:01	log 0.1 / log 0.1	0.9471	0.99	0.9485	0.99	0.9419	0.9523	0.9190	0.9661	0.9485	0.99	0.94856	0.99
10:21:01	tg 0.1 / tg 0.1	0.9423	0.99	0.9425	0.99	0.9419	0.9428	0.9043	0.9658	0.9425	0.99	0.93646	0.98
10:21:01	tg 0.3 / tg 0.3	0.8749	0.79	0.8714	0.79	0.8879	0.8619	0.7867	0.9305	0.8714	0.79	0.87140	0.79
10:21:01	tg 0.7 / tg 0.7	0.7855	0.57	0.7882	0.57	0.7759	0.7952	0.6849	0.8608	0.7882	0.57	0.78820	0.57
10:21:01	tg 0.9 / tg 0.9	0.9325	0.60	0.9379	0.54	0.9668	0.9214	0.8759	0.9797	0.9379	0.54	0.93797	0.54
10:21:01	log 0.1 / tg 0.1	0.9144	0.63	0.9198	0.61	0.9419	0.9071	0.8533	0.9645	0.9198	0.61	0.91981	0.61
10:21:01	log 0.3 / tg 0.3	0.4985	0.82	0.6354	0.83	0.0000	1.0000	0.0000	0.6354	0.3661	0.82	0.36459	0.20

Legenda: **EER** – Equal Error Rate, **Thre** – Threshold, **accSen** – Valor da Sensibilidade para a Maior Eficiência, **accEsp** – Valor da Especificidade para a Maior Eficiência, **accPpv** – Valor Preditivo Positivo para a Maior Eficiência, **accPpn** – Valor Preditivo Negativo para a Maior Eficiência, **AC** – Coeficiente de Correlação Aproximada, **J** – Índice de Youden.

Tabela 7 – Desempenho das RNAs utilizando o conjunto de Ktonas *et al.* (Continuação).

Neurônios	Ativação	EER	Thre	ACC	Thre	accSen	accEsp	accPpv	accPpn	AC	Thre	J	Thre
10:21:01	log 0.5 / tg 0.5	0.5000	0.22	0.6354	0.97	0.0000	1.0000	0.0000	0.6354	0.3645	0.25	0.36459	0.15
10:21:01	log 0.9 / tg 0.9	0.9322	0.69	0.9334	0.64	0.97095	0.9119	0.8634	0.9820	0.9334	0.64	0.93343	0.64
10:21:01	tg 0.1 / log 0.1	0.9430	0.99	0.9455	0.99	0.93361	0.9523	0.9183	0.9615	0.9440	0.98	0.94402	0.98
10:21:01	tg 0.3 / log 0.3	0.9418	0.97	0.9470	0.95	0.97095	0.9333	0.8931	0.9824	0.9470	0.95	0.9470	0.95
10:21:01	tg 0.5 / log 0.5	0.9444	0.92	0.9500	0.94	0.92946	0.9619	0.9333	0.9596	0.9500	0.94	0.94553	0.89
10:21:01	tg 0.7 / log 0.7	0.9400	0.8	0.9470	0.84	0.91701	0.9642	0.9364	0.9529	0.9455	0.71	0.94553	0.71
10:21:01	tg 0.9 / log 0.9	0.9423	0.99	0.9425	0.99	0.94191	0.9428	0.9043	0.9658	0.9425	0.99	0.93646	0.98
10:21:01	log 0.2 / log 0.2	0.9441	0.99	0.9470	0.99	0.93361	0.9547	0.9221	0.9616	0.9470	0.99	0.93948	0.98
10:21:01	log 0.3 / log 0.3	0.9462	0.99	0.9485	0.99	0.93776	0.9547	0.9224	0.9639	0.9485	0.99	0.94856	0.99
10:21:01	log 0.4 / log 0.4	0.9450	0.99	0.9470	0.99	0.93776	0.9523	0.9187	0.9638	0.9470	0.99	0.93948	0.98
10:21:01	log 0.5 / log 0.5	0.9450	0.99	0.9470	0.99	0.93776	0.9523	0.9187	0.9638	0.9470	0.99	0.94705	0.99
10:21:01	log 0.6 / log 0.6	0.9450	0.99	0.9470	0.99	0.93776	0.9523	0.9187	0.9638	0.9470	0.99	0.94705	0.99
10:21:01	log 0.7 / log 0.7	0.9480	0.99	0.9485	0.99	0.94606	0.9500	0.9156	0.9684	0.9485	0.99	0.94856	0.99
10:21:01	log 0.8 / log 0.8	0.9480	0.99	0.9485	0.99	0.94606	0.9500	0.9156	0.9684	0.9485	0.99	0.94856	0.99
10:21:01	log 0.9 / log 0.9	0.9423	0.99	0.9425	0.99	0.94191	0.9428	0.9043	0.9658	0.9425	0.99	0.93646	0.98

Legenda: **EER** – Equal Error Rate, **Thre** – Threshold, **accSen** – Valor da Sensibilidade para a Maior Eficiência, **accEsp** – Valor da Especificidade para a Maior Eficiência, **accPpv** – Valor Preditivo Positivo para a Maior Eficiência, **accPpn** – Valor Preditivo Negativo para a Maior Eficiência, **AC** – Coeficiente de Correlação Aproximada, **J** – Índice de Youden.

4.5 CONJUNTO DE LEMIEUX E BLUME (1983)

Lemieux e Blume (1983) propuseram um conjunto com 16 descritores morfológicos. Os treinamentos foram realizados com o tamanho da camada intermediária sendo variado entre 28 e 38 neurônios, com as funções de ativação logística e tangente hiperbólica, com inclinações de 0,1 a 0,9. Os resultados obtidos são apresentados na Tabela 8.

As células da tabela com preenchimento em cinza apresentam as situações em que a rede obteve o máximo valor para o índice de desempenho avaliado. São apresentados quatro índices de desempenho singulares e o limiar no qual eles ocorrem (Thre): taxa de erro igual (EER), eficiência (ACC), coeficiente de correlação aproximada (AC) desenvolvido por Burset e Guigó (1996) e índice de Youden (J).

Em nenhum dos testes, as redes apresentaram eficiência com valores inferiores a 0,6. O maior valor de eficiência foi de 0,9364 obtido no treinamento 16:28:1, log 0,1, log 0,1, no *threshold* 0,95. Nestes mesmos treinamento e *threshold*, também foi registrado o melhor AC apresentando valor de 0,9364, o maior EER com valor de 0,9331 e o maior J com valor de 0,95.

Este resultado sugere que o treinamento 16:28:1,log 0,1,log 0,1, pode ser considerado como o melhor dentre os treinamentos do conjunto de Lemieux e Blume (1983), uma vez que seu resultado é máximo para os quatro índices estatísticos analisados (EER, ACC, AC e J).

Tabela 8 – Desempenho das RNAs utilizando o conjunto de Lemieux e Blume.

Neurônios	Ativação	EER	Thre	ACC	Thre	accSen	accEsp	accPpv	accPpn	AC	Thre	J	Thre
16:28:01	log 0.1 / log 0.1	0.9331	0.94	0.9364	0.95	0.9294	0.9404	0.8996	0.9587	0.9364	0.95	0.9364	0.95
16:29:01	log 0.1 / log 0.1	0.9260	0.97	0.9304	0.92	0.9751	0.9047	0.8545	0.9844	0.9304	0.92	0.9304	0.92
16:30:01	log 0.1 / log 0.1	0.9260	0.97	0.9304	0.92	0.9751	0.9047	0.8545	0.9844	0.9304	0.92	0.9304	0.92
16:31:01	log 0.1 / log 0.1	0.9278	0.96	0.9319	0.93	0.9709	0.9095	0.8602	0.9820	0.9319	0.93	0.9319	0.93
16:32:01	log 0.1 / log 0.1	0.9236	0.96	0.9319	0.93	0.9709	0.9095	0.8602	0.9820	0.9319	0.93	0.9319	0.93
16:33:01	log 0.1 / log 0.1	0.9278	0.96	0.9319	0.93	0.9709	0.9095	0.8602	0.9820	0.9319	0.93	0.9319	0.93
16:34:01	log 0.1 / log 0.1	0.9278	0.96	0.9319	0.93	0.9709	0.9095	0.8602	0.9820	0.9319	0.93	0.9319	0.93
16:35:01	log 0.1 / log 0.1	0.9299	0.96	0.9319	0.93	0.9709	0.9095	0.8602	0.9820	0.9319	0.93	0.9319	0.93
16:36:01	log 0.1 / log 0.1	0.9278	0.96	0.9319	0.93	0.9709	0.9095	0.8602	0.9820	0.9319	0.93	0.9319	0.93
16:37:01	log 0.1 / log 0.1	0.9278	0.96	0.9319	0.93	0.9709	0.9095	0.8602	0.9820	0.9319	0.93	0.9319	0.93
16:38:01	log 0.1 / log 0.1	0.9278	0.96	0.9319	0.93	0.9709	0.9095	0.8602	0.9820	0.9319	0.93	0.9319	0.93
16:33:01	tg 0.1 / tg 0.1	0.8734	0.41	0.8789	0.38	0.9419	0.8428	0.7747	0.9619	0.8789	0.38	0.8789	0.38
16:33:01	tg 0.3 / tg 0.3	0.7811	0.26	0.8275	0.26	0.6099	0.9523	0.8802	0.8097	0.8275	0.26	0.8275	0.26
16:33:01	tg 0.7 / tg 0.7	0.8588	0.77	0.8441	0.77	0.9128	0.8047	0.7284	0.9415	0.8441	0.77	0.8441	0.77
16:33:01	tg 0.9 / tg 0.9	0.8370	0.90	0.8456	0.90	0.8049	0.8690	0.7791	0.8859	0.8366	0.89	0.8366	0.89
16:33:01	log 0.1 / tg 0.1	0.91446	0.63	0.9137	0.63	0.91701	0.91191	0.85659	0.95037	0.90923	0.40	0.909228	0.40
16:33:01	log 0.3 / tg 0.3	0.50000	0.21	0.6354	0.95	0.00000	1.0000	1.00000	0.6354	0.3646	0.35	0.364599	0.34

Legenda: **EER** – Equal Error Rate, **Thre** – Threshold, **accSen** – Valor da Sensibilidade para a Maior Eficiência, **accEsp** – Valor da Especificidade para a Maior Eficiência, **accPpv** – Valor Preditivo Positivo para a Maior Eficiência, **accPpn** – Valor Preditivo Negativo para a Maior Eficiência, **AC** – Coeficiente de Correlação Aproximada, **J** – Índice de Youden.

Tabela 8 – Desempenho das RNAs utilizando o conjunto de Lemieux e Blume (Continuação)..

Neurônios	Ativação	EER	Thre	ACC	Thre	accSen	accEsp	accPpv	accPpn	AC	Thre	J	Thre
16:33:01	log 0,5 / tg 0,5	0,50000	0,23	0,6354	1,00	0,00000	1,00000	1,00000	0,6354	0,3646	0,45	0,364599	0,56
16:33:01	log 0,9 / tg 0,9	0,92902	0,66	0,9304	0,64	0,95436	0,91667	0,86793	0,97222	0,93041	0,64	0,930408	0,64
16:33:01	tg 0,1 / log 0,1	0,91684	0,68	0,9228	0,65	0,93776	0,91429	0,8626	0,96241	0,92284	0,65	0,922844	0,65
16:33:01	tg 0,3 / log 0,3	0,92487	0,34	0,9289	0,33	0,93776	0,92381	0,87597	0,96278	0,9289	0,33	0,928896	0,33
16:33:01	tg 0,5 / log 0,5	0,9299	0,17	0,9289	0,16	0,93776	0,92381	0,87597	0,96278	0,9289	0,16	0,927383	0,14
16:33:01	tg 0,7 / log 0,7	0,92783	0,96	0,9319	0,93	0,97095	0,90952	0,86029	0,98201	0,93192	0,93	0,931921	0,93
16:33:01	tg 0,9 / log 0,9	0,92783	0,96	0,9319	0,93	0,97095	0,90952	0,86029	0,98201	0,93192	0,93	0,931921	0,93
16:33:01	log 0,2 / log 0,2	0,92694	0,96	0,9319	0,92	0,9751	0,90714	0,85766	0,9845	0,93192	0,92	0,931921	0,92
16:33:01	log 0,3 / log 0,3	0,92902	0,96	0,9319	0,93	0,97095	0,90952	0,86029	0,98201	0,93192	0,93	0,931921	0,93
16:33:01	log 0,4 / log 0,4	0,92902	0,96	0,9319	0,93	0,97095	0,90952	0,86029	0,98201	0,93192	0,93	0,931921	0,93
16:33:01	log 0,5 / log 0,5	0,92783	0,96	0,9319	0,93	0,97095	0,90952	0,86029	0,98201	0,93192	0,93	0,931921	0,93
16:33:01	log 0,6 / log 0,6	0,92545	0,96	0,9319	0,93	0,97095	0,90952	0,86029	0,98201	0,93192	0,93	0,931921	0,93
16:33:01	log 0,7 / log 0,7	0,92545	0,96	0,9319	0,93	0,97095	0,90952	0,86029	0,98201	0,93192	0,93	0,931921	0,93
16:33:01	log 0,8 / log 0,8	0,92664	0,96	0,9319	0,92	0,9751	0,90714	0,85766	0,9845	0,93192	0,92	0,931921	0,92
16:33:01	log 0,9 / log 0,9	0,92752	0,96	0,9319	0,92	0,9751	0,90714	0,85766	0,9845	0,93192	0,92	0,931921	0,92

Legenda: **EER** – Equal Error Rate, **Thre** – Threshold, **accSen** – Valor da Sensibilidade para a Maior Eficiência, **accEsp** – Valor da Especificidade para a Maior Eficiência, **accPpv** – Valor Preditivo Positivo para a Maior Eficiência, **accPpn** – Valor Preditivo Negativo para a Maior Eficiência, **AC** – Coeficiente de Correlação Aproximada, **J** – Índice de Youden.

4.6 CONJUNTO DE PEREIRA (2003)

Pereira (2003) definiu um conjunto com 43 descritores, portanto, os treinamentos foram realizados com o tamanho da camada intermediária sendo variado entre 82 e 92 neurônios, com as funções de ativação logística e tangente hiperbólica, com inclinações de 0,1 a 0,9. Os resultados obtidos são apresentados na Tabela 9.

As células da tabela com preenchimento em cinza apresentam as situações em que a rede obteve o máximo valor para o índice de desempenho avaliado. São apresentados quatro índices de desempenho singulares e o limiar no qual eles ocorrem (Thre): taxa de erro igual (EER), eficiência (ACC), coeficiente de correlação aproximada (AC) desenvolvido por Burset e Guigó (1996) e índice de Youden (J).

Novamente, as redes neurais não apresentaram valores de eficiência inferiores a 0,6. A maior eficiência obtida foi de 0,87, no treinamento 43:87:1, com as funções de ativação tg-log 0,3 (*threshold* 0,83) e também o maior AC no valor 0,87764.

Já o maior EER no valor 0,8683 foi obtido no treinamento e teste com a função de ativação tg-log 0,5 (*threshold* 0,60).

O maior índice J foi obtido no *threshold* 0,79 com a configuração 43:87:1 log 0,2 / log 0,2 com valor de 0,86405.

Estes resultados sugerem que o treinamento 43:87:1, tg 0,3, log 0,3, pode ser considerado como o melhor dentre os treinamentos do conjunto de Pereira (2003), uma vez que seu resultado é máximo para dois dos quatro índices estatísticos e elevado para os outros, mostrando diferença inferior a 1% entre eles.

Tabela 9 – Desempenho das RNAs utilizando o conjunto de Pereira (2003).

Neurônios	Ativação	EER	Thre	ACC	Thre	accSen	accEsp	accPpv	accPpn	AC	Thre	J	Thre
43-82:1	log 0.1 / log 0.1	0.8585	0.92	0.85952	0.92	0.85477	0.8622	0.7803	0.91206	0.85952	0.92	0.85045	0.88
43-83:1	log 0.1 / log 0.1	0.8585	0.92	0.85952	0.92	0.85477	0.8622	0.7803	0.91206	0.85952	0.92	0.85045	0.88
43-84:1	log 0.1 / log 0.1	0.8585	0.92	0.85952	0.92	0.85477	0.8622	0.7803	0.91206	0.85952	0.92	0.85045	0.88
43-85:1	log 0.1 / log 0.1	0.8585	0.92	0.85952	0.92	0.85477	0.8622	0.7803	0.91206	0.85952	0.92	0.85045	0.88
43-86:1	log 0.1 / log 0.1	0.8585	0.92	0.85952	0.92	0.85477	0.8622	0.7803	0.91206	0.85952	0.92	0.85045	0.88
43-87:1	log 0.1 / log 0.1	0.8585	0.92	0.85952	0.92	0.85477	0.8622	0.7803	0.91206	0.85952	0.92	0.85045	0.88
43-88:1	log 0.1 / log 0.1	0.8585	0.92	0.85952	0.92	0.85477	0.8622	0.7803	0.91206	0.85952	0.92	0.85045	0.88
43-89:1	log 0.1 / log 0.1	0.8585	0.92	0.85952	0.92	0.85477	0.8622	0.7803	0.91206	0.85952	0.92	0.85045	0.88
43-90:1	log 0.1 / log 0.1	0.8585	0.92	0.85952	0.92	0.85477	0.8622	0.7803	0.91206	0.85952	0.92	0.85045	0.88
43-91:1	log 0.1 / log 0.1	0.8585	0.92	0.85952	0.92	0.85477	0.8622	0.7803	0.91206	0.85952	0.92	0.85045	0.88
43-92:1	log 0.1 / log 0.1	0.8585	0.92	0.85952	0.92	0.85477	0.8622	0.7803	0.91206	0.85952	0.92	0.85045	0.88
43-87:1	tg 0.1 / tg 0.1	0.6461	0.12	0.66163	0.13	0.09544	0.9857	0.7931	0.65561	0.54985	0.12	0.54985	0.12
43-87:1	tg 0.3 / tg 0.3	0.8080	0.54	0.79758	0.54	0.84647	0.7696	0.6777	0.89751	0.79758	0.54	0.79758	0.54
43-87:1	tg 0.7 / tg 0.7	0.6209	0.57	0.63595	0.59	0.36515	0.7909	0.5000	0.68519	0.6148	0.54	0.6148	0.54
43-87:1	tg 0.9 / tg 0.9	0.6007	0.79	0.63595	0.93	0.00000	1.0000	0.0000	0.63595	0.60725	0.76	0.60725	0.76
43-87:1	log 0.1 / tg 0.1	0.5000	0.22	0.63595	0.89	0.00000	1.0000	0.0000	0.63595	0.36405	0.66	0.36405	0.30
43-87:1	log 0.3 / tg 0.3	0.5000	0.440	0.63595	1.00	0.00000	1.0000	0.0000	0.63595	0.36405	0.65	0.36405	0.30

Legenda: EER – Equal Error Rate, Thre – Threshold, accSen – Valor da Sensibilidade para a Maior Eficiência, accEsp – Valor da Especificidade para a Maior Eficiência, accPpv – Valor Preditivo Positivo para a Maior Eficiência, accPpn – Valor Preditivo Negativo para a Maior Eficiência, AC – Coeficiente de Correlação Aproximada, J – Índice de Youden.

Tabela 9 – Desempenho das RNAs utilizando o conjunto de Pereira (2003) (Continuação).

Neurônios	Ativação	EER	Thre	ACC	Thre	accSen	accEsp	accPpv	accPpn	AC	Thre	J	Thre
43:87:1	log 0,5 / tg 0,5	0,5000	0,33	0,63595	1,00	0,00000	1,0000	0,0000	0,63595	0,36405	0,23	0,36405	0,54
43:87:1	log 0,9 / tg 0,9	0,8627	0,70	0,87311	0,75	0,82573	0,9002	0,8257	0,90024	0,87311	0,75	0,86254	0,66
43:87:1	tg 0,1 / log 0,1	0,8683	0,76	0,87163	0,84	0,80083	0,9121	0,8391	0,88889	0,86858	0,76	0,85952	0,65
43:87:1	tg 0,3 / log 0,3	0,8659	0,75	0,87764	0,83	0,80913	0,9168	0,8478	0,89352	0,87764	0,83	0,86103	0,66
43:87:1	tg 0,5 / log 0,5	0,8683	0,60	0,87613	0,78	0,80498	0,9168	0,8471	0,89146	0,87462	0,67	0,86254	0,44
43:87:1	tg 0,7 / log 0,7	0,8561	0,87	0,87163	0,93	0,80083	0,9121	0,8391	0,88889	0,85952	0,75	0,85952	0,75
43:87:1	tg 0,9 / log 0,9	0,8585	0,92	0,85952	0,92	0,85477	0,8622	0,7803	0,91206	0,85952	0,92	0,85045	0,88
43:87:1	log 0,2 / log 0,2	0,8627	0,82	0,87462	0,88	0,81743	0,9073	0,8347	0,89671	0,87462	0,88	0,86405	0,79
43:87:1	log 0,3 / log 0,3	0,8635	0,83	0,87311	0,89	0,81328	0,9073	0,8340	0,89461	0,8716	0,86	0,86254	0,8
43:87:1	log 0,4 / log 0,4	0,8627	0,82	0,87462	0,88	0,81743	0,9073	0,8347	0,89671	0,87462	0,88	0,86405	0,79
43:87:1	log 0,5 / log 0,5	0,8627	0,88	0,87764	0,93	0,80083	0,9216	0,8539	0,88991	0,87764	0,93	0,85801	0,77
43:87:1	log 0,6 / log 0,6	0,8582	0,87	0,86858	0,92	0,81743	0,8978	0,8208	0,89574	0,86254	0,82	0,86254	0,82
43:87:1	log 0,7 / log 0,7	0,8618	0,82	0,87613	0,90	0,78008	0,9311	0,8663	0,8809	0,87613	0,9	0,85499	0,69
43:87:1	log 0,8 / log 0,8	0,8627	0,83	0,87009	0,91	0,77593	0,9239	0,8538	0,8781	0,87009	0,91	0,85196	0,71
43:87:1	log 0,9 / log 0,9	0,8603	0,89	0,87462	0,94	0,80498	0,9144	0,8434	0,8912	0,87462	0,94	0,85952	0,78

Legenda: **EER** – Equal Error Rate, **Thre** – Threshold, **accSen** – Valor da Sensibilidade para a Maior Eficiência, **accEsp** – Valor da Especificidade para a Maior Eficiência, **accPpv** – Valor Preditivo Positivo para a Maior Eficiência, **accPpn** – Valor Preditivo Negativo para a Maior Eficiência, **AC** – Coeficiente de Correlação Aproximada, **J** – Índice de Youden.

4.7 CONJUNTO DE SOVIERZOSKI (2009)

Sovierzoski (2009) definiu um conjunto com 30 descritores, portanto, os treinamentos foram realizados com o tamanho da camada intermediária sendo variado entre 56 e 66 neurônios, com as funções de ativação logística e tangente hiperbólica, com inclinações de 0,1 a 0,9. Os resultados obtidos são apresentados na Tabela 10.

As células da tabela com preenchimento em cinza apresentam as situações em que a rede obteve o máximo valor para o índice de desempenho avaliado. São apresentados quatro índices de desempenho singulares e o limiar no qual eles ocorrem (Thre): taxa de erro igual (EER), eficiência (ACC), coeficiente de correlação aproximada (AC) desenvolvido por Burset e Guigó (1996) e índice de Youden (J).

Novamente, nenhuma rede neural apresentou eficiência inferior a 0,6. O conjunto com a configuração 30:61:1 log 0,3 / log 0,3 pode ser considerado como o melhor dentre os treinamentos do conjunto de Sovierzoski (2009), uma vez que seu resultado é máximo para todos quatro índices estatísticos (EER, ACC, AC e J).

Tabela 10 – Desempenho das RNAs utilizando o conjunto de Sovierzoski (2009).

Neurônios	Ativação	EER	Thre	ACC	Thre	accSen	accEsp	accPpv	accPpn	AC	Thre	J	Thre
30:56:1	log 0,1 / log 0,1	0,92694	0,91	0,9289	0,88	0,95851	0,91191	0,86194	0,97456	0,9289	0,88	0,9289	0,88
30:57:1	log 0,1 / log 0,1	0,92694	0,91	0,9289	0,88	0,95851	0,91191	0,86194	0,97456	0,9289	0,88	0,9289	0,88
30:58:1	log 0,1 / log 0,1	0,92694	0,91	0,93041	0,90	0,94191	0,92381	0,87645	0,96517	0,93041	0,90	0,9289	0,88
30:59:1	log 0,1 / log 0,1	0,92694	0,91	0,93041	0,90	0,94191	0,92381	0,87645	0,96517	0,93041	0,90	0,9289	0,88
30:60:1	log 0,1 / log 0,1	0,92694	0,91	0,93192	0,90	0,94191	0,92619	0,87985	0,96526	0,93192	0,90	0,9289	0,88
30:61:1	log 0,1 / log 0,1	0,92694	0,91	0,93192	0,90	0,94191	0,92619	0,87985	0,96526	0,93192	0,90	0,93192	0,90
30:62:1	log 0,1 / log 0,1	0,92694	0,91	0,93192	0,90	0,94191	0,92619	0,87985	0,96526	0,93192	0,90	0,93192	0,90
30:63:1	log 0,1 / log 0,1	0,92694	0,91	0,93192	0,90	0,94191	0,92619	0,87985	0,96526	0,93192	0,90	0,93192	0,90
30:64:1	log 0,1 / log 0,1	0,92694	0,91	0,93192	0,90	0,94191	0,92619	0,87985	0,96526	0,93192	0,90	0,9289	0,88
30:65:1	log 0,1 / log 0,1	0,92694	0,91	0,93192	0,90	0,94191	0,92619	0,87985	0,96526	0,93192	0,90	0,93192	0,90
30:66:1	log 0,1 / log 0,1	0,92694	0,91	0,93192	0,90	0,94191	0,92619	0,87985	0,96526	0,93192	0,90	0,93192	0,90
30:61:1	tg 0,1 / tg 0,1	0,78774	0,38	0,83812	0,38	0,60166	0,97381	0,92949	0,8099	0,83812	0,38	0,83812	0,38
30:61:1	tg 0,3 / tg 0,3	0,84422	0,37	0,82451	0,37	0,91701	0,77143	0,69716	0,94186	0,82451	0,37	0,82451	0,37
30:61:1	tg 0,7 / tg 0,7	0,53032	0,82	0,6354	0,85	0,00000	1,00000	0,00000	0,6354	0,49773	0,80	0,54614	0,81
30:61:1	tg 0,9 / tg 0,9	0,7465	0,24	0,68684	0,24	0,96681	0,52619	0,53935	0,96507	0,68684	0,24	0,68684	0,24
30:61:1	log 0,1 / tg 0,1	0,5131	0,75	0,6354	0,76	0,00000	1,00000	0,00000	0,6354	0,38124	0,75	0,38124	0,75
30:61:1	log 0,3 / tg 0,3	0,53691	0,75	0,6354	0,76	0,00000	1,00000	0,00000	0,6354	0,4115	0,75	0,41150	0,75

Legenda: **EER** – Equal Error Rate, **Thre** – Threshold, **accSen** – Valor da Sensibilidade para a Maior Eficiência, **accEsp** – Valor da Especificidade para a Maior Eficiência, **accPpv** – Valor Preditivo Positivo para a Maior Eficiência, **accPpn** – Valor Preditivo Negativo para a Maior Eficiência, **AC** – Coeficiente de Correlação Aproximada, **J** – Índice de Youden.

Tabela 10 – Desempenho das RNAs utilizando o conjunto de Sovierzski (2009) (Continuação).

Neurônios	Ativação	EER	Thre	ACC	Thre	accSen	accEsp	accPpv	accPpn	AC	Thre	J	Thre
30:61:1	log 0,5 / tg 0,5	0,50000	0,20	0,6354	1,00	0,00000	1,00000	0,00000	0,6354	0,3646	0,32	0,36460	0,34
30:61:1	log 0,9 / tg 0,9	0,91803	0,68	0,92587	0,65	0,94191	0,91667	0,86641	0,96491	0,92587	0,65	0,92587	0,65
30:61:1	tg 0,1 / log 0,1	0,91684	0,38	0,92284	0,36	0,93361	0,91667	0,86539	0,9601	0,92284	0,36	0,92284	0,36
30:61:1	tg 0,3 / log 0,3	0,92337	0,15	0,92436	0,14	0,92946	0,92143	0,8716	0,95792	0,92436	0,14	0,92133	0,11
30:61:1	tg 0,5 / log 0,5	0,85596	0,60	0,88200	0,76	0,80083	0,92857	0,86547	0,89041	0,88200	0,76	0,87443	0,68
30:61:1	tg 0,7 / log 0,7	0,9029	0,08	0,91225	0,14	0,85062	0,94762	0,90308	0,91705	0,91225	0,14	0,90318	0,06
30:61:1	tg 0,9 / log 0,9	0,92902	0,91	0,93192	0,90	0,94606	0,92381	0,87692	0,96758	0,93192	0,90	0,93192	0,90
30:61:1	log 0,2 / log 0,2	0,92296	0,99	0,90772	0,99	0,97925	0,86667	0,80822	0,98645	0,90772	0,99	0,90772	0,99
30:61:1	log 0,3 / log 0,3	0,92902	0,91	0,93192	0,90	0,94606	0,92381	0,87692	0,96758	0,93192	0,90	0,93192	0,90
30:61:1	log 0,4 / log 0,4	0,92783	0,91	0,92738	0,91	0,92946	0,92619	0,87843	0,95813	0,92738	0,91	0,92436	0,88
30:61:1	log 0,5 / log 0,5	0,91922	0,91	0,92436	0,90	0,93776	0,91667	0,8659	0,9625	0,92284	0,88	0,92284	0,88
30:61:1	log 0,6 / log 0,6	0,92099	0,09	0,91982	0,90	0,92531	0,91667	0,86434	0,95534	0,91831	0,85	0,91831	0,85
30:61:1	log 0,7 / log 0,7	0,91861	0,90	0,91982	0,89	0,94191	0,90714	0,85338	0,96456	0,91982	0,89	0,91679	0,85
30:61:1	log 0,8 / log 0,8	0,91388	0,91	0,91831	0,86	0,96266	0,89286	0,83755	0,97656	0,91831	0,86	0,91831	0,86
30:61:1	log 0,9 / log 0,9	0,90943	0,85	0,91679	0,87	0,89212	0,93095	0,88115	0,93765	0,91679	0,87	0,90318	0,75

Legenda: **EER** – Equal Error Rate, **Thre** – Threshold, **accSen** – Valor da Sensibilidade para a Maior Eficiência, **accEsp** – Valor da Especificidade para a Maior Eficiência, **accPpv** – Valor Preditivo Positivo para a Maior Eficiência, **accPpn** – Valor Preditivo Negativo para a Maior Eficiência, **AC** – Coeficiente de Correlação Aproximada, **J** – Índice de Youden.

4.8 ANÁLISE COMPARATIVA

Hjorth (1970) e Ktonas *et al.* (1981) não apresentam os valores absolutos relacionados à detecção de espículas, Gotman (1980) apresenta a porcentagem de assimetria de cada descritor por canal. Entretanto, Gotman (1982) apresenta o número de detecções de paroxismos e sua porcentagem de acertos, que, conforme apresentado na sessão 2.4 traduz-se como valor preditivo positivo (VPP).

Ktonas *et al.* (1981) apresentam o valor médio de cada descritor. Sendo assim, não é possível obter os índices da tabela de contingência e, por consequência, nem todos os índices derivados. Na Tabela 11 são apresentados os índices estatísticos (%) dos autores e os valores estatísticos das simulações realizadas neste trabalho. Com fundo cinza encontram-se as melhores redes testadas, utilizando o índice de eficiência como prioridade.

Tabela 11 – Comparação entre os valores originais dos autores e os das simulações

Conjunto	Eficiência	Sens.	Espe.	VPP	VPN
Hjorth (1970)	#	#	#	#	#
	71,86	52,30	83,10	63,95	75,22
Frost (1979)	#	95,60*	#	86,13*	#
	91,07	91,70	90,71	85,00	95,01
Gotman (1980, 1982)	#	#	#	22,00	#
	93,49	91,28	94,76	90,90	94,98
Ktonas <i>et al.</i> (1981)	#	#	#	#	#
	95,00	92,94	96,19	93,33	95,96
Lemieux e Blume (1983)	#	#	#	41,66*	#
	93,64	92,94	94,04	89,96	95,87
Pereira (2003)	#	90,00	96,00	95,00	92,00
	87,76	80,91	91,68	84,78	89,35
Sovierzoski (2009)	92,50	95,96	89,11	89,62	95,74
	93,19	94,60	92,38	87,69	96,75

* Calculado através dos valores absolutos fornecidos pelo autor.

não é mencionado índices ou métricas para extração ou cálculo do trabalho original.

Analizando a Tabela 11, observa-se que os resultados obtidos com utilização dos conjuntos descritos por Frost (1979) e Sovierzoski (2009) mantiveram-se similares aos resultados encontrados pelos autores, apesar da mudança da base de dados.

Os resultados obtidos utilizando o conjunto de Pereira (2003) apresentaram índices de desempenho significativamente maiores que os relatados pela autora, em especial cita-se a sensibilidade que apresentou-se 9,09% superior e o valor preditivo positivo que apresentou aumento de 10,22% com a base de dados e metodologia utilizada neste trabalho.

A maior eficiência foi encontrada no conjunto de descritores apresentado por Ktonas *et al.* (1981) com valor de 95%.

Com a segunda melhor eficiência aparece o conjunto de Lemieux e Blume (1983) com valor de 93,64%. O conjunto de descritores desses autores apresentou valor preditivo positivo significativamente maior que o relatado pelo o autor, com diferença de 48,29%.

Os valores de eficiência encontrados através dos conjuntos dos autores Lemieux e Blume (1983) e Sovierzoski (2009), apresentaram muita semelhança. Porém Sovierzoski (2009) apresentou os maiores valores de sensibilidade e valor preditivo negativo.

Dos sete conjuntos de descritores apresentados, o conjunto de Ktonas *et al.* (1981) foi considerado o melhor entre eles, para a caracterização dos padrões epleptiformes tomando como base a métrica de eficiência. E o conjunto proposto por Hjorth (1970) foi considerado um dos piores, apresentado discriminação inferior a 72%. No geral, os demais conjuntos apresentam resultados promissores.

A Tabela 12 apresenta o melhor desempenho obtido para cada um dos sete conjuntos de descritores treinados e as métricas de desempenho EER, eficiência, correlação aproximada, e índice de Youden.

Analizando os dados da Tabela 12, ficou evidente que o melhor desempenho do conjunto de Hjorth (1970) apresentou valores muito inferiores aos valores dos demais conjuntos, novamente, corroborando a análise da eficiência realizada previamente.

Tabela 12 – Melhor desempenho de cada conjunto treinado e suas respectivas métricas de desempenho.

	Hjorth (1970)	Frost (1979)	Gotman (1980)	Ktonas <i>et al.</i> (1981)	Lemieux e Blume (1983)	Pereira (2003)	Sovierzski (2009)
Neurônios da Rede	3:5:1	6:13:1	6:8:1	10:21:1	16:28:1	43:87:1	30:61:1
Ativação da Rede	log 0,1 / log 0,1	log 0,9 /tg 0,9	log 0,1 / log 0,1	tg 0,5 / log 0,5	log 0,1 / log 0,1	tg 0,3 / log 0,3	log 0,3 / log 0,3
EER	0,718	0,903	0,931	0,944	0,933	0,865	0,929
Eficiência	0,723	0,910	0,934	0,950	0,936	0,877	0,931
Sens.	0,539	0,917	0,912	0,929	0,929	0,809	0,946
Esp.	0,828	0,907	0,947	0,961	0,940	0,916	0,923
VPP	0,639	0,850	0,909	0,933	0,899	0,847	0,876
VPN	0,752	0,950	0,949	0,959	0,958	0,893	0,967
AC	0,697	0,910	0,933	0,950	0,936	0,877	0,931
Valor J	0,700	0,910	0,933	0,945	0,936	0,861	0,931

5 CONCLUSÃO

Este trabalho iniciou com uma revisão bibliográfica dos conjuntos de descritores morfológicos utilizados para detectar padrões epileptiformes em sinais de EEG e permitiu identificar que os estudos a cerca do tema utilizam natureza e quantidades de descritores distintos. Porém, cada um desses estudos utilizou bases de dados, classificadores e métricas de análise de desempenho diferentes dificultando uma comparação entre o resultado obtido por cada um desses estudos.

Diante desse cenário, a metodologia desenvolvida neste trabalho utilizou uma única base de dados, o mesmo tipo de classificador e um único conjunto de métricas de análise de desempenho com objetivo de realizar uma análise comparativa adequada entre os conjuntos de descritores analisados. Conclui-se que o uso de quatro métricas seria adequado para avaliar a contribuição para a detecção automática: maior eficiência (ACC) do classificador, além da taxa de erro igual (EER), do coeficiente de correlação aproximada (AC) e do índice de Youden (Y).

No tocante aos estudos reproduzidos segundo a metodologia proposta, o conjunto de descritores proposto por Hjorth (1970) apresentou uma eficiência máxima de 71,86%, e um índice de sensibilidade de 52,30%, ou seja, nada muito diferente da probabilidade de qual dos lados uma moeda pode assumir. Esse fato deve-se ao pequeno número de descritores (apenas três), associados a eles não estarem diretamente relacionados às características morfológicas temporais dos padrões epileptiformes.

Por sua vez, o conjunto de descritores apresentado por Ktonas *et al.* (1981) composto por dez descritores, apresentou os maiores valores para as quatro métricas utilizadas na metodologia deste trabalho trazendo evidências que este conjunto de descritores seja o mais promissor para a identificação de padrões epileptiformes, com eficiência máxima de 95%.

Os valores das métricas obtidas com os conjuntos de Gotman (1980) com seis descritores e Lemieux e Blume (1983) com 16 descritores são bem próximas dos obtidos com Ktonas *et al.* (1981). Em parte, este resultado seria esperado pela similaridade entre os descritores dos três conjuntos, porém utilizam quantidades diferentes de descritores morfológicos.

O desempenho obtido com os descritores de Sovierzoski (2009) com 30 descritores foi melhor que os obtidos com Pereira (2003) com 45 descritores em todas as métricas aplicadas. O trabalho de Sovierzoski

(2009) envolvia um subconjunto dos descritores apresentados por Pereira (2003). A melhora no desempenho poderia sugerir que a redução do número de descritores utilizados contribuiu para a melhoria da capacidade de classificação dos padrões epileptofirmes.

A metodologia se mostrou adequada para a comparação dos diversos conjuntos de descritores morfológicos dos estudos selecionados e o uso das métricas adotadas nesta metodologia identificou que o acréscimo de descritores decorrentes de operações aritméticas ou associações não representa necessariamente melhora no desempenho do classificador.

6 TRABALHOS FUTUROS

O *software* que realiza a extração dos descritores fez uso de dados de EEG com montagem unipolar/referencial no eletrodo Pz. Sendo assim, não foi realizado o condicionamento do algoritmo para processar dados de EEG com montagem bipolar. Sugere-se a inclusão de novas bases de dados..

Outra sugestão é juntar os conjuntos de descritores morfológicos apresentados neste trabalho e, através do uso de ferramentas estatísticas, como por exemplo, Análise de Discriminantes e verificar a real contribuição de cada descritor na detecção automática de padrões epileptiformes.

REFERÊNCIAS

AARABI, A.; GREBE, R.; WALLOIS, F. A multistage knowledge-based system for EEG seizure detection in newborn infants. **Clinical Neurophysiology**, v. 118, n. 12, p. 2781–2797, dez. 2007.

ACIR, N.; OZTURA, I.; KUNTALP, M.; BAKLAN, B.; GÜZELİŞ, C. Automatic detection of epileptiform events in EEG by a three-stage procedure based on artificial neural networks. **IEEE transactions on bio-medical engineering**, v. 52, n. 1, p. 30–40, jan. 2005.

ARGOUD, F. I. M. **Contribuição à automatização da detecção e análise de eventos epileptiformes em eletroencefalograma**. Tese (Doutorado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Santa Catarina, 2001.

ARGOUD, F. I. M.; DE AZEVEDO, F. M.; NETO, J. M.; GRILLO, E. SADE3: an effective system for automated detection of epileptiform events in long-term EEG based on context information. **Medical and Biological Engineering and Computing**, v. 44, n. 6, p. 459–470, 4 jun. 2006.

BOOS, C. F. **Avaliação de Descritores Morfológicos de eventos epileptiformes utilizando Análise de Componentes Principais**. Dissertação (Mestrado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Santa Catarina, Florianópolis, 2011.

BOOS, C. F. **Contribuição ao reconhecimento automático de padrões epileptiformes em sinais de eletroencefalograma utilizando análise morfológica**. Tese (Doutorado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Santa Catarina, Florianópolis, 2015.

BRODERSEN, K. H.; ONG, C. S.; STEPHAN, K. E.; BUHMANN, J. M. The Balanced Accuracy and Its Posterior Distribution. [s.l.]: IEEE, 2010, p. 3121–3124.

BURSET, M.; GUIGÓ, R. Evaluation of Gene Structure Prediction Programs. **Genomics**, v. 34, n. 3, p. 353–367, jun. 1996.

BYFORD, G. H. An EEG analysis using simple arithmetic. **Electroencephalography and Clinical Neurophysiology**, v. 27, n. 7, p. 665–666, set. 1969.

CARRIE, J. R. . A technique for analyzing transient EEG abnormalities. **Electroencephalography and Clinical Neurophysiology**, v. 32, n. 2, p. 199–201, fev. 1972.

DAVEY, B. L. K.; FRIGHT, W. R.; CARROLL, G. J.; JONES, R. D. Expert system approach to detection of epileptiform activity in the EEG. **Medical & Biological Engineering & Computing**, v. 27, n. 4, p. 365–370, jul. 1989.

DINGLE, A A; JONES, R. D.; CARROLL, G. J.; FRIGHT, W. R. A multistage system to detect epileptiform activity in the EEG. **IEEE transactions on bio-medical engineering**, v. 40, n. 12, p. 1260–8, dez. 1993.

EBERHART, R. C.; DOBBINS, R. W.; WEBBER, W. R. S. Neural network design considerations for EEG spike detection. [s.l.]: IEEE, 1989a, p. 97–98.

EBERHART, R. C.; DOBBINS, R. W.; WEBBER, W. R. S. CaseNet: a neural network tool for EEG waveform classification. [s.l.]: IEEE Comput. Soc. Press, 1989b, p. 60–68.

EBERHART, R. C.; DOBBINS, R. W.; WEBBER, W. R. S. EEG waveform analysis using CaseNet. [s.l.]: IEEE, 1989c, p. 2046–2047.

FAURE, C. Attributed strings for recognition of epileptic transients in EEG. **International Journal of Bio-Medical Computing**, v. 16, n. 3-4, p. 217–229, maio 1985.

FAWCETT, T. An introduction to ROC analysis. **Pattern Recognition Letters**, v. 27, n. 8, p. 861–874, jun. 2006.

FROST, J. D. Microprocessor-based EEG spike detection and quantification. **International Journal of Bio-Medical Computing**, v. 10, n. 5, p. 357–373, set. 1979.

GEVINS, A. S.; YEAGER, C. L.; DIAMOND, S. L.; SPIRE, J.; ZEITLIN, G. M.; GEVINS, A. H. Automated analysis of the electrical activity of the human brain (EEG): A progress report. **Proceedings of the IEEE**, v. 63, n. 10, p. 1382–1399, 1975.

GLAS, A. S.; LIJMER, J. G.; PRINS, M. H.; BONSEL, G. J.; BOSSUYT, P. M. M. The diagnostic odds ratio: a single indicator of test performance. **Journal of Clinical Epidemiology**, v. 56, n. 11, p. 1129–1135, nov. 2003.

GLOVER JR., J. R.; RAGHAVAN, N.; KTONAS, P. Y.; FROST, J. D. Context-based automated detection of epileptogenic sharp transients in the EEG: elimination of false positives. **IEEE transactions on bio-medical engineering**, v. 36, n. 5, p. 519–527, maio 1989.

GLOVER JR., J. R.; VARMAZIS, D. N.; KTONAS, P. Y.; FROST, J. D. Continued Development Of A Knowledge-based System To Detect Epileptogenic Sharp Transients In The EEG. [s.l.]: IEEE, 1990, p. 1374–1375.

GOLDBERG, P.; SAMSON-DOLLFUS, D.; GREMY, F. An approach to an automatic pattern recognition of the electroencephalogram: Background rhythm and paroxysmal elements. **Methods of Information in Medicine**, v. 12, n. 3, p. 155–163, 1973.

GOTMAN, J. Quantitative measurements of epileptic spike morphology in the human EEG. **Electroencephalography and clinical neurophysiology**, v. 48, n. 5, p. 551–557, maio 1980.

GOTMAN, J. Automatic recognition of epileptic seizures in the EEG. **Electroencephalography and Clinical Neurophysiology**, v. 54, n. 5, p. 530–540, nov. 1982.

GOTMAN, J.; GLOOR, P. Automatic recognition and quantification of interictal epileptic activity in the human scalp EEG. **Electroencephalography and Clinical Neurophysiology**, v. 41, n. 5, p. 513–529, nov. 1976.

GOTMAN, J.; IVES, J. .; GLOOR, P. Automatic recognition of interictal epileptic activity in prolonged EEG recordings.

Electroencephalography and Clinical Neurophysiology, v. 46, n. 5, p. 510–520, maio 1979.

GOTMAN, J.; WANG, L. Y. State-dependent spike detection: concepts and preliminary results. **Electroencephalography and clinical ...**, v. 83, n. 1, p. 11–19, jul. 1991.

GOTMAN, J.; WANG, L. Y. State dependent spike detection: validation. **Electroencephalography and clinical neurophysiology**, v. 83, n. 1, p. 12–8, jul. 1992.

HALFORD, J. J.; SCHALKOFF, R. J.; ZHOU, J.; BENBADIS, S. R.; TATUM, W. O.; TURNER, R. P.; SINHA, S. R.; FOUNTAIN, N. B.; ARAIN, A.; PRITCHARD, P. B.; KUTLUAY, E.; MARTZ, G.; EDWARDS, J. C.; WATERS, C.; DEAN, B. C. Standardized database development for EEG epileptiform transient detection: EEGnet scoring system and machine learning analysis. **Journal of Neuroscience Methods**, v. 212, n. 2, p. 308–316, jan. 2013.

HARNER, R. Automatic EEG spike detection. **Clinical EEG and neuroscience**, v. 40, n. 4, p. 262–70, 1 out. 2009.

HELLMANN, G. Multifold features determine linear equation for automatic spike detection applying neural nin interictal ECoG. **Clinical neurophysiology : official journal of the International Federation of Clinical Neurophysiology**, v. 110, n. 5, p. 887–94, maio 1999.

HILL, A. G.; TOWNSEND, H. R. A. The automatic estimation of epileptic spike activity. **International Journal of Bio-Medical Computing**, v. 4, n. 2, p. 149–156, abr. 1973.

HJORTH, B. EEG analysis based on time domain properties. **Electroencephalography and Clinical Neurophysiology**, v. 29, n. 3, p. 306–310, set. 1970.

HJORTH, B. The physical significance of time domain descriptors in EEG analysis. **Electroencephalography and Clinical Neurophysiology**, v. 34, n. 3, p. 321–325, mar. 1973.

JONES, R. D.; DINGLE, A. A. Automated detection of epileptiform transients in the EEG using a multi-channel expert system approach. ... **in Medicine and ...**, p. 696–697, 1989.

JONES, R. D.; DINGLE, A. A. A system for detecting epileptiform discharges in the EEG: real-time operation and clinical trial. ... **in Medicine and ...**, v. 3, p. 948–949, 1996.

KO, C. W.; LIN, Y. D. An EEG spike detection algorithm using artificial neural network with multi-channel correlation. ... **in Medicine and Biology ...**, v. 4, n. 4, p. 2070–2073, 1998.

KOOI, K. A. Voltage-time characteristics of spikes and other rapid electroencephalographic transients: semantic and morphological considerations. **Neurology**, v. 16, n. 1, p. 59–59, 1 jan. 1966.

KTONAS, P. .; LUOH, W. .; KEJARIWAL, M. .; REILLY, E. .; SEWARD, M. . Computer-aided quantification of EEG spike and sharp wave characteristics. **Electroencephalography and Clinical Neurophysiology**, v. 51, n. 3, p. 237–243, mar. 1981.

KTONAS, P. Y.; GLOVER, J. R.; JANSEN, B. H.; DAWANT, B. M.; RAGHAVAN, N.; FROST, J. D. A knowledge-based approach to the automated detection of EEG waveforms. [s.l.]: IEEE, 1988, p. 1365–1366 vol.3.

KTONAS, P. Y.; SMITH, J. R. Quantification of abnormal EEG spike characteristics. **Computers in biology and medicine**, v. 4, n. 2, p. 157–163, dez. 1974.

KUTLU, Y.; KUNTALP, M.; KUNTALP, D. Optimizing the performance of an MLP classifier for the automatic detection of epileptic spikes. **Expert Systems with Applications**, v. 36, n. 4, p. 7567–7575, 2009.

LEMIEUX, J. F.; BLUME, W. T. Automated morphological analysis of spikes and sharp waves in human electrocorticograms. **Electroencephalography and clinical neurophysiology**, v. 55, n. 1, p. 45–50, jan. 1983.

LONGO, D. L.; KASPER, D. L.; JAMESON, J. L.; FAUCI, A. S.; HAUSER, S. L.; LOSCALZO, J. Harrison Principios de Medicina Interna. In: **Harrison Principios de medicina interna**. [s.l: s.n.]. v. 18, p. 1761–1770.

LUCCAS, F. J. C.; ANGHINAH, R.; BRAGA, N. I. O.; FONSECA, L. C.; FROCHTENGARTEN, M. L.; JORGE, M. S.; KANDA, P. A. M. Recomendações Para O Registro / Interpretação Do Mapeamento Topográfico Do Eletrencefalograma E Potenciais Evocados. **Neurologia**, v. 57, n. 1, p. 132–146, 1999.

MALMIVUO, J.; PLONSEY, R. Bioelectromagnetism: Principles and Applications of Bioelectric and Biomagnetic Fields. **New York: Oxford University Press**, 1995.

MATTHEWS, B. W. W. Comparison of the predicted and observed secondary structure of T4 phage lysozyme. **Biochimica et Biophysica Acta (BBA) - Protein Structure**, v. 405, n. 2, p. 442–451, 1975.

MAZUROWSKI, M. A.; HABAS, P. A.; ZURADA, J. M.; LO, J. Y.; BAKER, J. A.; TOURASSI, G. D. Training neural network classifiers for medical decision making: The effects of imbalanced datasets on classification performance. **Neural Networks**, v. 21, n. 2-3, p. 427–436, mar. 2008.

MONTENEGRO, M. A.; CENDES, F.; GUERREIRO, M. M.; GUERREIRO, C. A. M. **EEG na Prática Clínica**. 2. ed. Rio de Janeiro: Revinter, 2012.

OLIVEIRA, P. G. DE; QUEIROZ, C.; SILVA, F. L. DA. Spike detection based on a pattern recognition approach using a microcomputer. **Electroencephalography and Clinical Neurophysiology**, v. 56, n. 1, p. 97–103, jul. 1983.

PEREIRA, M. DO C. V. **Avaliação de Técnicas de Pré-Processamento de Sinais de EEG para Detecção de Eventos Epileptogênicos Utilizando Redes Neurais Artificiais**. Universidade Federal de Santa Catarina, Florianópolis, 2003.

PEWSNER, D. Ruling a diagnosis in or out with “SpPIn” and “SnNOut”: a note of caution. **BMJ**, v. 329, n. 7459, p. 209–213, 24 jul. 2004.

PILLAI, J.; SPERLING, M. R. Interictal EEG and the diagnosis of epilepsy. **Epilepsia**, v. 47, n. SUPPL. 1, p. 14–22, 2006.

POWERS, D. M. W. Evaluation: From Precision, Recall and F-Measure To Roc, Informedness, Markedness & Correlation. **Journal of Machine Learning Technologies**, v. 2, n. 1, p. 37, 2011.

SALTZBERG, B.; HEATH, R. G.; EDWARDS, R. J. EEG spike detection in schizophrenia research. [s.l.]: 1967, p. 266.

SANEI, S.; CHAMBERS, J. A. **EEG Signal Processing**. 1. ed. West Sussex: John Wiley & Sons Ltd, 2007a.

SANEI, S.; CHAMBERS, J. A. **EEG Signal Processing**. West Sussex, England: John Wiley & Sons Ltd, 2007b.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas – Curso Prático**. 1. ed. [s.l.]: Artliber, 2010.

SMITH, J. R. Automatic analysis and detection of EEG spikes. **IEEE transactions on bio-medical engineering**, v. 21, n. 1, p. 1–7, jan. 1974.

SOVIERZOSKI, M. A. **Avaliação de Descritores Morfológicos na Identificação de Eventos Epileptiformes**. Tese (Doutorado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica, Florianópolis, 2009.

UBEYLI, E. D. Statistics over features: EEG signals analysis. **Computers in biology and medicine**, v. 39, n. 8, p. 733–41, ago. 2009.

VERA, R. S.; BLUME, W. T. A clinically effective spike recognition program: its use at electrocorticography. **Electroencephalography and clinical neurophysiology**, v. 45, n. 4, p. 545–8, out. 1978.

WALTER, D. O.; MULLER, H. F.; JELL, R. M. Semiautomatic Quantification of Sharpness of EEG Phenomena. **IEEE Transactions on Biomedical Engineering**, v. BME-20, n. 1, p. 53–55, jan. 1973.

WEBBER, W. R.; LITT, B.; WILSON, K.; LESSER, R. P. Practical detection of epileptiform discharges (EDs) in the EEG using an artificial neural network: a comparison of raw and parameterized EEG data. **Electroencephalography and clinical neurophysiology**, v. 91, n. 3, p. 194–204, set. 1994.

WEIR, B. The morphology of the spike-wave complex. **Electroencephalography and Clinical Neurophysiology**, v. 19, n. 3, p. 284–290, set. 1965.

WHO. **Epilepsy - Fact sheet N°999**. Disponível em: <<http://www.who.int/mediacentre/factsheets/fs999/en/>>. Acesso em: 20 jun. 2015.

WILSON, S. B.; EMERSON, R. Spike detection: A review and comparison of algorithms. **Clinical Neurophysiology**, v. 113, n. 12, p. 1873–1881, dez. 2002.

WILSON, S. B.; SCHEUER, M. L.; PLUMMER, C.; YOUNG, B.; PACIA, S. Seizure detection: Correlation of human experts. **Clinical Neurophysiology**, v. 114, n. 11, p. 2156–2164, nov. 2003.

WILSON, S. B.; TURNER, C. A.; EMERSON, R. G.; SCHEUER, M. L. Spike detection II: automatic , perception-based detection and clustering. v. 110, p. 404–411, 1999.

WITTE, H.; EISELT, M.; PATAKOVA, I.; PETRANEK, S.; GRIESSBACH, G.; KRAJCA, V.; ROTHER, M. Use of discrete Hilbert transformation for automatic spike mapping: a methodological investigation. **Medical & biological engineering & computing**, v. 29, n. 3, p. 242–8, maio 1991.

YODEN, W. J. Index for rating diagnostic tests. **Cancer**, v. 3, n. 1, p. 32–5, jan. 1950.

Dissertação apresentada ao Programa de Pós-graduação em Engenharia Elétrica, Departamento de Engenharia Elétrica e Eletrônica, do Centro Tecnológico da Universidade Federal de Santa Catarina, como requisito para obtenção do Título de Mestre em Engenharia Elétrica.

Orientador: Fernando Mendes de Azevedo, Dr. Sc.

Florianópolis, 2016